

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY SİNİR AĞLARI VE BİR OTOMOTİV
FİRMASINDA SATIŞ TALEP TAHMİNİ
UYGULAMASI**

YÜKSEK LİSANS TEZİ

Meral SARI

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ
Enstitü Bilim Dalı : YÖNEYLEM ARAŞTIRMASI
Tez Danışmanı : Yrd.Doç.Dr.Halil İbrahim DEMİR

Ocak 2016

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY SINIR AĞLARI VE BİR OTOMOTİV
FİRMASINDA SATIŞ TALEP TAHMİNİ
UYGULAMASI

YÜKSEK LİSANS TEZİ

Meral SARI

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ
Enstitü Bilim Dalı : YÖNEYLEM ARAŞTIRMASI

Bu tez 19/01/2016 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.

Yrd.Dos.Dr. Halil İbrahim Demirel
.....
Jüri Başkanı



Prof.Dr. İbrahim Şil
.....
Üye



Yrd.Dos.Dr. Muhammed AKSAY
.....
Üye



BEYAN

Tez içerisindeki tüm verilerin akademik ve etik kurallara bağılı kalarak tarafımdan elde edildiğini, kullanılan tüm verilerin doğru olduğuna, yararlanılan eserlerin bilimsel normlara uygun şekilde atıfta bulunulduğuna, tez içerisinde bulunan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışılmasında kullanılmadığını beyan ederim.

Meral SARI

19/ 01 /2016

TEŐEKKÜR

Bu alıřmada grő ve nerileri ile katkıda bulunan, sabır ve anlayıő gsteren ve alıőma boyunca desteęini esirgemeyen deęerli hocam Sayın Yrd. Do. Dr. Halil İbrahim Demir'e sonsuz teőekkrlerimi sunarım. Ayrıca bana desteklerini esirgemeyen Őahin Motor Yatakları Planlama Mdr Fsun Kavaklı Kunduz ve Ynetim Kurulu yesi Selen Aysu'ya, son olarak ta tm hayatım boyunca sonsuz sevgi ve desteklerini esirgemeyen aileme teőekkrlerimi bir bor bilirim.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	v
ŞEKİLLER LİSTESİ	vi
TABLOLAR LİSTESİ	viii
ÖZET	ix
SUMMARY	x
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
TALEP TAHMİNİ VE TAHMİN YÖNTEMLERİ	3
2.1. Talep Tahminin Tanımı	3
2.2. Talep Tahmininin Aşamaları	5
2.3. Talep Tahmininin Varsayımları	6
2.4. Talep Tahmin Yöntemlerinin Sınıflandırılması	6
2.4.1. Nitel yöntemler	7
2.4.1.1. Uzman görüşünün alınması	7
2.4.1.2. Delphi tekniği	7
2.4.1.3. Anket yöntemi	8
2.4.1.4. Senaryo analizi	8
2.4.1.5. Satış gücü birleşimi	9
2.4.2. Nicel yöntemler	9
2.4.2.1. Zaman serileri analizi	10
2.4.2.2. Nedensel yöntemler	18
2.4.2.3. Yapay zeka tabanlı yöntemler	22

2.5. Tahmin Yöntemlerinin Doğruluğunun Ölçülmesi	26
--	----

BÖLÜM 3.

YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ	29
3.1. Yapay Sinir Ağları ile İlgili Temel Kavramlar	29
3.2. Yapay Sinir Ağları Genel Özellikleri	30
3.3. Yapay Sinir Ağları Tarihsel Gelişimi	32
3.4. Yapay Sinir Ağlarının Avantajları	34
3.5. Yapay Sinir Ağları Dezavantajları	35
3.6. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları	35
3.6.1. Biyolojik sinir hücresi	35
3.6.2. Yapay sinir hücresi	37
3.6.2.1. Girdiler	38
3.6.2.2. Ağırlıklar	38
3.6.2.3. Toplama fonksiyonu	38
3.6.2.4. Aktivasyon fonksiyonu	39
3.6.2.5. Çıktılar.....	42
3.7. Yapay Sinir Ağları Modelleri.....	42
3.7.1. İleri beslemeli ağlar.....	43
3.7.2. Geri beslemeli ağlar.....	44
3.8. Yapay Sinir Ağlarında Öğrenme Algoritmaları.....	45
3.8.1. Danışmanlı öğrenme.....	46
3.8.2. Danışmansız öğrenme.....	48
3.8.3. Takviyeli öğrenme.....	49
3.8.4. Karma stratejiler.....	50
3.9. Yapay Sinir Ağlarında Öğrenme Kuralları.....	50
3.9.1. Hebb kuralı.....	50
3.9.2. Hopfield kuralı.....	50
3.9.3. Kohenon kuralı.....	51
3.9.4. Delta kuralı.....	52
3.10. Geri Yayılım Algoritması ve Çok Katmanlı Algılayıcılar	52
3.10.1. ÇKA' da ileri besleme aşaması.....	53
3.10.2. ÇKA' da geri besleme aşaması.....	55
3.11. Yapay Sinir Ağı Çalışma Prosedürü.....	58

BÖLÜM 4.

TALEP TAHMİNİ UYGULAMASI	59
4.1. Talep Tahmini Probleminin Tanımlanması.....	59
4.2. Yapay Sinir Ağı Mimarisi.....	64
4.3. Yapay Sinir Ağı Matlab Uygulamaları.....	65
4.3.1. Öğrenme katsayısının belirlenmesi.....	66
4.3.2. Momentum katsayısının belirlenmesi.....	67
4.3.3. Çevrim sayısının belirlenmesi.....	69
4.3.4. Nöron sayısının belirlenmesi.....	70
4.3.5. Gizli hücre sayısının belirlenmesi.....	71
4.4. Yapay Sinir Ağının Eğitilmesi.....	72
4.5. Sonuçların Test Edilmesi ve Değerlendirilmesi.....	77
4.6. Çoklu Regresyon Analizi ile Talep Tahmini Uygulaması.....	80
4.7. Zaman Serileri Analizi ile Talep Tahmini Uygulaması.....	83
4.7.1. Hareketli ortalama yöntemi.....	83
4.7.2. Basit üssel düzgünleştirme yöntemi.....	85
4.7.3. Holt lineer ikili üssel düzgünleştirme yöntemi.....	86
4.7.4. Winters üssel düzgünleştirme yöntemi.....	88
4.8. Tahmin Yöntemlerinin Karşılaştırılması.....	89
4.9. Sonuç ve Öneriler.....	90
KAYNAKLAR.....	93
EKLER.....	97
ÖZGEÇMİŞ.....	101

SİMGELER VE KISALTMALAR LİSTESİ

AR	: Otoregresif süreç
ARIMA	: Durağan hale getirilmiş otoregresif hareketli ortalama
ARMA	: Otoregresif hareketli ortalama
CPI	: Tüketici fiyatları endeksi (ing.)
ÇKA	: Çok katmanlı algılayıcılar
GA	: Genetik algoritma
GDP	: Gayri safi yurtiçi hasıla (ing.)
GSYH	: Gayri safi yurtiçi hasıla
İMKB	: İstanbul menkul kıymetler borsası
MA	: Hareketli ortalama
MAE	: Ortalama mutlak hata
MAPE	: Ortalama mutlak yüzde hata
MSE	: Ortalama hata kareleri
MSPE	: Kök ortalama yüzde hata kare
OSD	: Otomotiv sanayi derneği
PPI	: Üretici fiyatları endeksi
R	: Korelasyon katsayısı
RA	: Regresyon analizi
RBF	: Radyal tabanlı fonksiyonlar
TUİK	: Türkiye istatistik kurumu
TÜFE	: Tüketici fiyatları endeksi
ÜFE	: Üretici fiyatları endeksi
Y _t	: Gözlenen gerçek değer
YSA	: Yapay sinir ağları

ŞEKİLLER LİSTESİ

Şekil 2.1. Box Jenkins metodolojisi.....	16
Şekil 2.2. En küçük kareler yöntemi.....	21
Şekil 2.3. Bulanık mantığın elemanları ve çalışması.....	24
Şekil 2.4. Bulanıklaştırma – netleştirme birimli bulanık sistem	24
Şekil 3.1. Yapay sinir hücresi.....	29
Şekil 3.2. Biyolojik sinir hücresi.....	36
Şekil 3.3. Yapay sinir hücresi gösterimi.....	37
Şekil 3.4. Sigmoid fonksiyonunun şekilsel gösterimi.....	41
Şekil 3.5. İleri beslemeli nöron ağı.....	43
Şekil 3.6. Geri beslemeli YSA.....	45
Şekil 3.7. Danışmanlı öğrenme yapısı.....	47
Şekil 3.8. Danışmansız öğrenme yapısı.....	48
Şekil 3.9. Takviyeli öğrenme yapısı.....	49
Şekil 3.10. Bir Hopfield ağı örneği.....	51
Şekil 3.11. İleri beslemeli geri yayılımlı yapay sinir ağı yapısı.....	54
Şekil 4.1. Üretim adetinin değişimi 2004-2014.....	60
Şekil 4.2. Gayri safi yurtiçi hasılanın değişimi 2004-2014.....	60
Şekil 4.3. Tüketici fiyatları endeksinin değişimi 2004-2014.....	61
Şekil 4.4. Üretici fiyatları endeksinin değişimi 2004-2014.....	61
Şekil 4.5. İhracat adetinin değişimi 2004-2014.....	62
Şekil 4.6. İMKB gecelik faiz oranının değişimi 2004-2014.....	62
Şekil 4.7. Dolar kurunun değişimi 2004- 2014.....	63
Şekil 4.8. Araç parkı sayısının değişimi 2004-2014.....	63
Şekil 4.9. Matlab'ta yeni ağ yaratma penceresi	73
Şekil 4.10. Yapay sinir ağı gösterimi	73
Şekil 4.11. Matlab'ta YSA eğitim ekranı	74

Şekil 4.12. Eğitim, doğrulama ve test kümelerine ilişkin hata performansları.....	75
Şekil 4.13. Matlab'ta öğrenme, doğrulama ve test kümelerine ilişkin regresyon..	75
Şekil 4.14. Matlab'ta YSA test ekranı	78
Şekil 4.15. YSA ile bulunan tahmini değerler ile gerçek değerlerin grafik gösterimi.....	80
Şekil 4.16. Hareketli ortalama yöntemine göre bulunan tahmini ve gerçek değerlerin gösterilmesi.....	83
Şekil 4.17. Basit üssel düzgünleştirme yöntemine göre bulunan tahmini ve gerçek değerlerin gösterilmesi.....	86
Şekil 4.18. Holt lineer ikili üssel düzgünleştirme yöntemine göre bulunan tahmini ve gerçek değerlerin gösterilmesi.....	87
Şekil 4.19. Winters üssel düzgünleştirme yöntemine göre bulunan tahmini ve gerçek değerlerin gösterilmesi.....	89

TABLolar LİSTESİ

Tablo 3.1.	Biyolojik sınır hücresi ve YSA benzeşimleri.....	37
Tablo 3.2.	Toplam fonksiyonunun türleri	39
Tablo 3.3.	Bazı aktivasyon fonksiyonları.....	41
Tablo 4.1.	Öğrenme katsayısının belirlenmesi	66
Tablo 4.2.	Momentum katsayısının belirlenmesi	68
Tablo 4.3.	Çevrim sayısının belirlenmesi	69
Tablo 4.4.	Nöron sayısının belirlenmesi	71
Tablo 4.5.	Gizli hücre sayısının belirlenmesi	72
Tablo 4.6.	YSA parametreleri	76
Tablo 4.7.	Giriş nöronları ile gizli katman nöronları arasındaki ağırlık değerleri	76
Tablo 4.8.	Gizli katmandaki nöronların eşik değerleri	77
Tablo 4.9.	Gizli katmandaki nöronlar ile çıkış katmanındaki nöronlar arasındaki ağırlık değerleri	77
Tablo 4.10.	Çıkış katmanındaki nöronun eşik değerleri	77
Tablo 4.11.	YSA'ya göre tahmin performansı	78
Tablo 4.12.	YSA sonucu bulunan tahmini değerler ile gerçek değerlerin karşılaştırılması	79
Tablo 4.13.	Excelde regresyon istatistikleri	81
Tablo 4.14.	Çoklu regresyon ile bulunan tahmini değerler	82
Tablo 4.15.	Çoklu regresyona göre tahmin performansı	83
Tablo 4.16.	Hareketli ortalama yöntemine göre bulunan tahmini değerler.....	83
Tablo 4.17.	Basit üssel düzgünleştirme yöntemiyle bulunan tahmini değerler....	85
Tablo 4.18.	Holt lineer ikili üssel düzgünleştirme yöntemiyle bulunan tahminler	86
Tablo 4.19.	Winters üssel düzgünleştirme yöntemiyle bulunan tahmini değerler	88
Tablo 4.20.	Tahmin yöntemlerinin sonuçlarının karşılaştırılması.....	89

ÖZET

Anahtar kelimeler: Talep Tahmini, Yapay Sinir Ağları, Regresyon Analizi

Bu çalışmada son zamanlarda sıkça kullanılan bir tahmin yöntemi olan Yapay Sinir Ağları (YSA) kullanılarak motor yataklarının satış talep tahmini yapılmaya çalışılmıştır. Satış talebini etkileyen çok fazla faktör olduğundan dolayı, doğru ve güvenilir tahminlere gereksinim vardır.

Firmaların varoluş amaçlarının başında, kar yapmakla birlikte süreklilik sağlamak, çalışanlarını ve müşterilerini memnun etmek gelir. Müşteri memnuniyetinin kazanılmasındaki en etken yol, müşteri tarafından talep edilen mal ve hizmeti müşterinin istediği zamanında göndermektir. Siparişleri, istenen zamanda gönderebilmek için, öncelikle hangi dönemlerde ne kadarlık sipariş olabileceğini tahmin etmek gereklidir.

Motor satış talebini etkileyen faktörler; dolar kuru, GSYH, araç parkı sayısı, üretilen araç sayısı, ihracat sayısı, faiz oranı, Tüfe ve Üfe' dir. Yapay sinir ağının ürettiği sonuçların gerçeği ne kadar yansıttığı istatistiksel olarak araştırılmıştır. Elde edilen sonuçlar, Regresyon Analizi (RA) ve zaman serileri ile yapılan tahmin sonuçlarıyla karşılaştırılmış ve yapay sinir ağları ile gerçeğe daha yakın tahminler elde edilmiştir.

ARTIFICIAL NEURAL NETWORKS AND SALES DEMAND FORECASTING APPLICATION IN THE AUTOMOTIVE INDUSTRY

SUMMARY

Keywords: Sales Forecast, Artificial Neural Networks, Regression Analysis

In this study, recently, an estimation method frequently used Artificial Neural Networks have attempted sales demand forecast of engine bearing. Because a lot of factors that affect the sales demand, there is a need for accurate and reliable estimates.

At the beginning of the existence of objective company comes to provide continuity with making profits and to satisfy employees and customers. The most effective way in winning customer satisfaction is to send the goods and services demanded by customers timely when the customer wants. Orders, to send the requested time, it is first necessary to estimate how much the order in which period may be.

Factors affecting the engine bearing sales demand are dolar exchange rates, GDP, number of tractor parking, the number of vehicles produced, the number of exports, interest rate, CPI and PPI. The fact that the neural network also produces the results were statistically analyzed how much reflects. Artificial neural network from the obtained results were compared to those of regression and time series and the results found with artificial neural networks, gave close results more real than others.

BÖLÜM 1. GİRİŞ

Artan rekabet ve sürekli deęişen dünyaya ayak uydurabilmek için firmalar geleceęi tahmin etmek isterler. İřte bu yüzden talep tahmini, firmaların kısa dönemli ve uzun dönemli hedeflerine ulaşmada kullanılacak en temel araçlardan bir tanesidir. Üretilen mal, hizmet ve tüketici davranışlarının farklı olmasından dolayı çeşitli talep tahmini yöntemleri mevcuttur.

Talep tahmininde kullanılan yöntemler genellikle nitel ve nicel yöntemler olarak ikiye ayrılır. Nitel yöntemler daha çok uzman görüşlerine ve kişisel tecrübelere dayanmaktadır. Nicel yöntemler, istatistiksel ve matematiksel verilere dayanır. Talep tahmin yöntemlerinin güvenilirlięi, o yöntemin başarılı olması için en önemli faktörüdür. Son yıllarda yapay zeka tabanlı yöntemlerin gelişmesiyle, klasik tahmin yöntemlerine oranla daha doğru tahminlerin yapıldığı görülmektedir. Yapay zeka tabanlı yöntemlerden yapay sinir aęları tahminlemede yaygın olarak kullanılmaktadır. Yapay sinir aęları, istatistiksel veri kullanması yönünden nicel yöntemlere, faktörler arasındaki ilişki ve derecelerini öğrenmesi yönüyle nitel yöntemlere benzer ve etkin bir talep tahmini yöntemi olarak son yıllarda önem kazanmaktadır.

Bu tez kapsamında otomotiv yan sanayi ürünlerinden biri olan motor yataęı satış miktarı çeşitli talep tahmini yöntemleri ve yapay sinir aęları ile hesaplanmış ve bu yöntemler birbirleri ile karşılaştırılmıştır.

Otomotiv sektörü, Türkiye ekonomisinde önemli rol oynamaktadır. Bu sektörün içinde bulunan her firma için satış talebinin doğru tahmin edilmesi, o firmanın hayatta kalabilmesi için zorunlu bir gerekliliktir. Pazarlama yöneticileri, pazar payının ve firmanın büyüme hızının gelecekteki dönemlerde nasıl olacağını tahmin etmek zorundadırlar. Söz konusu ürün için, toplam pazar genişlięinin büyüklüğü,

hedef pazarın ne olduđu, gelecekteki bu büyüklükleri nasıl deęiőeceğini, firmanın satış potansiyelinin ne kadarını deęerlendirebildiđi, dönemsel satış trendlerinin ne olacađı tespiti, pazarlama amaç ve planlarının dođru biçimde ortaya konulması maliyetlerin ve firmanın diđer kaynaklarının planlanması için önem taşımaktadır.

İkinci bölümde talep tahminin tanımlanması ve talep tahmininde kullanılan yöntemlerin sınıflandırılması yer almaktadır. Talep tahmini yöntemlerinden kalitatif ve kantitatif olanlar ve alternatif yöntemler olarak yapay zeka yöntemlerinin kullanıldığına deęinilmiştir.

Üçüncü bölümde yapay sinir ađları açıklanmış ve özellikle (ÇKA) çok katmanlı algılayıcı modeli ayrıntılı olarak açıklanmıştır. Yapay sinir ađlarının tanımı, genel özellikleri, tarihsel gelişimi, avantajları, dezavantajları, yapısı & temel elemanları, modelleri, öğrenme algoritmaları ve öğrenme kuralları üzerinde durulmuştur.

Dördüncü bölümde uygulama modeli ve bu kapsamda yapılan çalışmalar ayrıntılı olarak anlatılmıştır. Yapay sinir ađları kullanılarak talep tahmini yapılmış ve sonuçları incelenmiştir. Ayrıca çoklu regresyon modeli de uygulanmış ve sonuçları yapay sinir ađları ile bulunan sonuçlarla karşılaştırılmıştır. Yapay sinir ađları ile yapılan tahmin sonuçlarının çoklu regresyon modeline göre üstün olduđu vurgulanmıştır. Ayrıca tahminleme yöntemi olarak zaman serileri analizindeki bir kaç yöntemde denenmiştir. Bütün bu yöntemler karşılaştırılmış ve MAPE hata deęeri olarak en düşük deęeri yapay sinir ađları ile önerilen model vermiştir.

BÖLÜM 2. TALEP TAHMİNİ VE TAHMİN YÖNTEMLERİ

Bu bölümde talep tahmininin tanımı, aşamaları, nasıl yapıldığı, talep tahmin yöntemleri anlatılmıştır.

2.1. Talep Tahmininin Tanımı

Talep, tüketicilerin bir ürün veya hizmeti belirli bir fiyat seviyesinden almaya hazır oldukları miktardır. Talebi etkileyen faktörler arasında; ürün ve hizmetin fiyatı, tüketicilerin gelir seviyeleri, ihtiyacın şiddeti, tüketici alışkanlıkları, mevsimsel etkenler sayılabilir [2]. Tahmin, en basit anlamıyla, geçmişe bakarak geleceğin kestirilmesi anlamına gelmektedir.

Talep tahmini, bir firmanın ürünlerin satışlarının gelecek dönemler için ne olacağını belirlemek ve önceden bilmek için, geçmiş dönem verilerinin düzenlenmesi ve analiz edilmesi sürecine denilmektedir. Bu ürünlerden ne kadar satılacağı, tüketicilerin taleplerinin hangi ürünler üzerinde olacağı ve bu taleplerin hangi tarihlerde gerçekleşeceğini talep tahminleri ile öğrenmek mümkün olabilmektedir.

Talep tahmininde üç tür yöntem kullanılmaktadır. Bu yöntemler kantitatif, kalitatif ve yapay zeka tabanlı yöntemler olarak adlandırılmaktadırlar. Son dönemlerde teknolojinin gelişmesiyle yapay zeka tabanlı yöntemlerde kullanılmaya başlanmıştır. Kalitatif yöntemler daha çok kişisel çıkarımlara ve deneyimlere dayanırken, kantitatif yöntemler istatistiksel ve matematiksel yöntemlere dayanmaktadır. Klasik yöntemlerle çözülemeyen durumlarda, daha karmaşık veri yapılarını çözümlenebilen yapay zeka tabanlı yöntemler de çoğunlukla kullanılmaktadır [3].

Nitel tahmin yöntemi, çalışılan konu üzerinde uzman bir kişinin görüş ve deneyimlerini baz almaktadır [17]. Aynı veriler üzerinde farklı kişiler farklı tahminlerde kullanılabilir. Bu yöntemin kullanılma nedeni, uygulamasının kolay olması ve çok fazla zaman almamasıdır. Ayrıca çoğunlukla ucuz olmaları ve ileri derecede istatistiksel işlemlere ihtiyaç duymaması da tercih edilme nedenleri arasında sayılabilmektedir.

Nicel yöntemler matematiksel ve istatistiksel yöntemlere baz almaktadır. Bu yöntemler eğer elimizde konu ile ilgili yeterli nümerik veriler varsa kullanılabilir. Geçmişe ait bilgilerin olması, bu bilgilerin sayısal olarak ifade edilmesi ve değişkenin geçmişte gösterdiği yapının gelecek zaman içinde devam edeceği şartlarını sağlıyorsa kullanılması uygundur.

Talep tahmin yönteminin seçiminde, tahminlerin kapsadığı zaman aralığı, tahminlerin hazırlanması için gerekli süre, verilere erişebilme, tahminleme sürecinde kullanılan kaynakların maliyeti, karar vericinin tolare edebileceği hata payı, tekniğin anlama ve uygulama açısından kolaylığı, yöntemi uygulayacak ve tahminleri kullanarak kararlar verecek olan bireylerin özellikleri vb. pek çok faktörün dikkate alınması lazımdır [1].

Talep tahminleri genellikle dört dönem için yapılmaktadır. Bunlar çok kısa süreli tahminler, kısa süreli tahminler, orta süreli tahminler ve uzun süreli tahminlerdir.

1. Çok kısa süreli tahminler: Genellikle günlük veya haftalık yapılan tahminlere denmektedir. Stokların kontrolü, günlük üretim programlarının hazırlanması ve sipariş vermek amacıyla yapılırlar.
2. Kısa süreli tahminler: Bir hafta ile altı ay arasında yapılan tahminlere denmektedir. Makine kapasitesi ve işgücü ayarlamaları amacıyla yapılırlar.
3. Orta süreli tahminler: Altı ay ile beş yıllık süre arasında yapılan tahminlere denmektedir. Tedarik süresi belirsiz olan satın almalarının planlanması için yapılmaları uygundur.

4. Uzun vadeli tahminler: Beş yıl ile daha uzun süreli olarak yapılan tahminlere denmektedir. Genellikle yeni yatırımlar yapılmadan önce bu tahminlerin yapılması daha uygundur.

Talep tahmininde göz önünde bulundurulması gereken ilkeler aşağıdaki gibidir:

1. Tahminler miktar veya çeşit bakımından büyük olan ürün grubu için yapılması daha müsaittir.
2. Tahminler kısa dönemler için daha doğruluğu daha fazladır.
3. Tahmin yöntemi kullanılmadan önce mutlaka performansının test edilmesi gerekir.
4. Tahmin kesin talebin yerini tutamaz.

2.2. Talep Tahmininin Aşamaları

1. Talebi etkileyen faktörlerin belirlenmesi: Talep tahmini yapmadan önce firmanın özellikleri, talep tahminin yapılacak olan ürünün özellikleri, firmanın durumu, firmanın hedeflerinin ne olduğu, aynı ürün için rakip firmalarının piyasada olup olmadığı, ülkenin ekonomik durumu, yaşanan veya yaşanması muhtemel teknolojik gelişimler vb. faktörlerin belirlenmesi gerekir ve bu ürünün talebi için ağırlığın ne olduğu tespit edilmelidir.
2. Verilerin toplanması: Tahmini etkileyecek olan faktörlerin belirlenmesi ve bu faktörlere ait verilerin toplanması, yapılacak olan talep tahmini çalışmasını en etkileyen en önemli aşamasıdır. Kullanılacak veriler geçmiş dönemlere ait verilere ait olabileceği gibi, bulunabilecek daha önceden oluşan istatistiksel ya da ülke ekonomisine ait iktisadi veriler de olabilmektedir.
3. Talep tahmin döneminin tespiti: Talep tahmini yapılması düşünülen zaman aralığı belirlenmektedir. Bu zaman aralığında tahminleme çalışması yapılmaktadır.
4. Talep tahmin yönteminin seçimi ve hata hesabı: Talep araştırılmasından elde edilmesi beklenen performansa göre tahmin yönteminin seçilmesi gerekmektedir. Ayrıntılı talep araştırılması gerektiren durumlar için fazla ayrıntılı inceleme yapmayan metotların kullanılması, istenilen sonuçların elde

edilmesini engelleyebilir. Bir tahminin doğruluğu, tahminlenen değerler ile gerçekleşen değerler arasındaki farktır. Bu farka hata denmektedir [2].

5. Tahmin sonuçlarının geçerliliğinin araştırılması: Yapılan tahminleme sonucunda bulunan sonuç ile gerçek değerler arasındaki farkın tespiti edilmesi ve bu farkın nedenlerinin araştırılması aşamasıdır. Bu nedenlerden en önemlisi toplanan verilerin doğruluk derecesine bağlıdır.

2.3. Talep Tahminin Varsayımları

1. Tahminler çoğu zaman gerçek değerlerden farklı olabilir. Bu yüzden tahminler büyük çoğunlukla yanlıştır. Bunun nedeni ise, tahmin yapılan dönemde öngörülemeyen durumların meydana gelebilmesidir.
2. Tahminler sadece bir rakamdan oluşmamalıdır. Doğru tahminler, belli bir rakam yerine geçerlilik aralığı veya tahmin hatası dağılımı verebilmelidir.
3. Grup tahminleri daha doğrudur.
4. Tahminlerin doğruluğunun, tahmin yapılan süre ile ters orantılı olduğu düşünülmektedir [2].

İyi bir tahminin özellikleri aşağıdaki gibidir:

1. İyi bir tahminin gerçek değerlere yakın bir değere sahip olması gerekir.
2. Tahmin maliyetinin, sağlanan faydadan fazla olmaması gerekir.
3. Yazılı olmalıdır.
4. Güvenilir olmalıdır.
5. Tahminden yararlanan kişilerin anlayabileceği seviyede olmalıdır.

2.4. Talep Tahmin Yöntemlerinin Sınıflandırılması

Talep tahmin yöntemleri temel olarak üç sınıfa ayrılır. Bunlar nitel yöntemler, nicel yöntemler ve yapay zeka tabanlı yöntemlerdir.

Nitel yöntemler çoğunlukla uzman kişilerin görüşlerine dayanırken, nicel yöntemler matematiksel ve istatistiksel hesaplamalara dayanır. Bu yöntemlerin yetersiz kaldığı durumda, yapay zeka tabanlı yöntemler kullanılmaktadır.

2.4.1. Nitel yöntemler

Verilere dayanarak bilimsel yöntemler yerine hissi, kişisel yani yargısal olarak yapılan tahminlerdir. Tahmin etme yöntemi bilimsel verilere dayanmaması nedeniyle tahmin performansı diğerlerine göre düşüktür [3].

Bu yöntemin kullanılabilmesi için elde yeterli veri olmaması veya bu veriler mevcut ama bu verileri analiz edecek kadar uzun süre olmaması gerekir. Bu yöntemin en önemli özelliği, sezgisel yargıları da talep tahmini sürecine dahil edebilmesidir.

2.4.1.1. Uzman görüşünün alınması

Tahmin yapılması istenilen konu üzerinde uzmanlığı olan personelin tecrübelerine, bilgilerine ve sezgilerine dayanarak yapılan tahmindir. Bu uzman kişi mali işler, satın alma, satış, üretim veya yönetim kurulundan birisi olabilir. Kısa dönemlerde karar verilmesi isteniliyorsa bu yöntem kullanılabilir. Bu sayede verilerle uğraşma zamanından tasarruf edilebilir. Bu yöntem basit, uygulanması kolay ve düşük maliyetli olmasından dolayı daha avantajlı olduğu düşünülür. Fakat tamamen kişisel görüşlere dayandığından dolayı yanlış sonuçlara götürebilme olasılığı diğerlerine göre daha yüksektir.

2.4.1.2. Delphi tekniği

Bu teknik bir ürüne ait gelecekte oluşması beklenen talebin tahmin edilebilmesi için, uzman kişilerin yüz yüze görüşmeden ve arda tartışma yapmadan talebin gelecekteki değerine karar vermelerine ve uzlaşmalarına imkan veren bir yöntemdir. Delphi tekniği, 1950'li yıllarda ABD'de RAND şirketinde çalışan Olaf Helmer ve Norman Dalkey adında iki araştırmacı tarafından geliştirilmiş ve uygulanmıştır. Delphi tekniğinin amacı; geleceğe ilişkin tahminlerde bulunmak, uzman görüşlerini ortaya

çıkarmak ve uzlaşmanın sağlanmasıdır. Bu teknik, çoğunlukla politik veya duygusal ortamlarda karar verme durumunda kalındığında veya kararların güçlü gruplar tarafından etkilenme olasılığı olduğu durumlarda kullanılır. Bu tekniği kullanan uzmanlara genellikle ardışık anketler uygulanır.

Genel olarak üç özelliğe sahiptir:

1. Katılımda gizlilik
2. Grup tepkisinin istatistiksel analizi
3. Kontrollü geri besleme

2.4.1.3. Anket yöntemi

Hedef tüketicilere, yeni bir ürün piyasaya sürülürken veya bu üründe değişiklik yapıldığında talebin tahmin edilebilmesi için anket yaptırılması yöntemidir.

Anket yoluyla geniş kitlelere ulaşmak, araştırmayı büyük gruplara dayandırmak daha kolaydır. Bu teknik para, zaman ve enerji bakımından araştırmacıya avantaj sağlar. Fakat bu teknikte güvenilirlik aramak genellikle zordur. Anketlerden derinlemesine bilgi edinme kolay olmamaktadır. Kişilerin soruları aynı derecede anlayamamaları veya cevaplarında açık olmamaları ve rastgele cevaplar vermeleri dezavantajları arasındadır. Araştırmacının bunu kontrol etme imkanı da genellikle bulunmamaktadır.

2.4.1.4. Senaryo analizi

Senaryolar geleneksel tahmin yöntemlerinden farklı olarak alternatif gelecekle ortaya koymakta ve aynı zamanda ekonometrik modellerin dışarıda bıraktığı konuları ve kalitatif görüşleri de kapsamaktadır. Senaryo analizi gerek kişisel düşünce farklılıklarının, gerekse gelecek ile ilgili belirsizliklerin modellenmesine fırsat tanınması nedeniyle yaratıcılığı teşvik etmektedir.

Senaryo analizi aynı zamanda benimsenen stratejilerin değişik gelecek senaryoları karşısındaki esneklikleri ve dayanıklılıklarının da test edilmesini sağlar. Böylelikle

stratejilerin kırılma noktaları ile ilgili göstergelerin belirlenmesi ve takip edilmeleri kolaylaşır. Ayrıca belirlenen stratejilerle ilgili risklerin azaltılması için kaynak planlamasına da olanak tanınır.

Senaryo analizi alternatif planların da esas plana yakın düzeyde hazırlanmasına yardımcı olmaktadır. Böylelikle, kurumun değişen şartlar karşısında uyum sağlama hızı artar. Geleceğin belirsizliğine karşı hazırlık için değişen şartlar karşısında atılacak adımların belirlenmesi, stratejik düşüncenin zenginliğini arttırmaktadır.

Senaryo planlama sürecinde geliştirilen ve analiz edilen senaryolar, mevcut durumu matematiksel modeller ile ileriye taşıyan klasik tahmin ve pazar araştırmalarından farklı şekilde, değişik alternatifleri göz önüne sermektedir. Böylelikle, uyarı sinyallerinin farkına vararak ve senaryoların altında yatan gerçekler açığa çıkarılarak; sürprizler önlenebilir, değişimlere ve şoklara daha kolay adapte olunarak, daha etkin şekilde davranılabilmektedir. Senaryo planlamadan beklenen sonuç, çalışanların gelecek hakkında sürekli olarak düşünmelerini ve görüş alışverişinde bulunmalarını sağlamaktır.

2.4.1.5. Satış gücü birleşimi

Satış personellerinin kendi satış bölgelerindeki satışların ne olacağını tahmin etmesidir. Tahminleme yaparken önceki satış trendini dikkate alırlar. Sonra her birinin tahmini birleştirilerek toplam tahmin elde edilir. Bu yöntem, uzman personelin görüşünün alınması yöntemine benzemektedir. Burada satış personeli firma için yeni ve sektörü bilgisi az ise uygulanmaması gerekmektedir.

2.4.2. Nicel yöntemler

Nicel tahmin yöntemleri geçmiş dönemlere ait fiili olarak gerçekleşmiş talep değerlerini esas alan istatistiksel yöntemlerdir. Talebin oluşmasına etki eden faktörler ile talep miktarı arasındaki ilişkinin gelecekte dönemler için de aynı şekilde eğilim göstereceği varsayımına dayanmaktadır. İstatistiksel metotlarla geçmiş dönem verileri incelenir ve bunlar esas alınarak gelecek dönemlere ait talep miktarları

bulunur. Bu yöntemler zaman serileri analizi ve nedensel yöntemler olmak üzere ikiye ayrılır. Kullanılan yöntemler; incelenen değişkende gözlenen gelişmelerin analiz edilmesi, veri serisinin dinamik özelliklerinin belirlenmesi ve bu özelliklerin matematiksel bir fonksiyon ile ifade edilerek geleceğe ilişkin öngörülerin yapılmasını içermektedir [2].

2.4.2.1. Zaman serileri analizi

Zaman serisi, geçmiş dönemlere ait veriler incelenerek, belli bir eğilim olup olmadığının belirlenip, geleceğe yönelik tahmin yapılmasıdır. Zaman sırasına konmuş geçmiş dönem verileridir. Zaman serisi analizinde, bu geçmiş dönem değerlerinin değişim biçimi araştırılır ve bu süreci temsil eden model kurulur. Bu modelle geleceğe yönelik talepler tahmin edilir.

Zaman serileri analizi çok geniş uygulama alanına sahiptir. Bu alanlar özellikle istatistik ve ekonomi gibi bilim dallarıdır. Zaman serisi, zaman içinde gözlenen ölçümlerin bir dizisidir. Eğer elimizde geçmiş verilere ait veriler bulunuyorsa zaman serileri yardımıyla bu verileri kullanarak gelecek yıllar hakkında tahminde bulunabiliriz.

Zaman serisini etkileyen beş ana faktör vardır. Bunlar; ortalama, eğilim, mevsimsel değişim, periyodik değişim, rastgele olaylardır.

1. Ortalama: Geçmiş döneme ait veriler, ortalama bir değer çevresinde gerçekleşir.
2. Eğilim (trend) : Sürekli olarak verilerin, aynı yönde değişen bir eğilim trend olarak tanımlanmaktadır. Bunun için regresyon modeli eğilim değişimini iyi gösteren bir matematiksel modeldir. Bu model bir doğru veya eğri olarak gösterilebilir.
3. Mevsimlik değişim: Mevsime bağlı olarak talebin değişmesidir. Mevsim olarak illa sıralı ayların olması şart değildir. Yakın taleplere sahip farklı aylarda mevsim olarak nitelendirilebilir. Örneğin, yılın değişik aylarında talebin artması veya azalması mevsim değişikliği olarak söylenebilir.

Mevsimlik bileşen genellikle üç aylık, aylık, haftalık vb. sınıflandırılmış verilerden oluşur. Düzenli olarak yinelenen değişim eğilimine sahiptir.

4. Konjonktürel Değişim: Geçmiş döneme ait verilerin, mevsimsele göre daha uzun zaman aralıklarında oluşan değişimlerine denmektedir. Genellikle kararsızlıklar veya değişen ekonomik şartlara bağlı olarak bir yıldan fazla süren değişimdir. Ekonomideki büyük çaplı değişimler sonucunda talepte de büyük çaplı değişim olur.
5. Rastgele Olaylar: Genellikle düzensiz ve anlaşılması zor olan olaylardır. Bu olaylar sonucunda talep oluşmaktadır. Genellikle hava değişimleri (sel, deprem vs.), grevler, savaşlar, savaş söylentileri, yasal değişiklikler gibi zamanlanmayan ve öncede kestirilemeyen olayların yol açtığı dalgalanmalardan meydana gelir. Örneğin; depremde yıkılan konutlar sonucunda, konut talebinin artmasıdır.

Zaman serileri analizinde aşağıdaki yöntemler uygulanmaktadır:

1. Basit aritmetik hareketli ortalama yöntemi: Bu yöntemde son n döneme ait değerlerin ortalaması, bir sonraki döneme ait tahmin edilmesi istenen değer (\hat{Y}) olarak alınır. Matematiksel ifadesi aşağıdaki gibidir. (Denklem 2.1)

$$\hat{Y}_i = \sum_{j=1}^n Y_{i-j} = \bar{Y} \quad (2.1)$$

Dönem sayısını belirlemek için genellikle deneme yanılma yöntemi kullanılmaktadır. Her yeni dönemde, en eski döneme ait değer ortalamadan atılarak son n dönemin değerlerinin ortalaması alınır. Hesaplar sonucu bulunan bu ortalama, bir sonraki değer tahmini değeridir.

2. Hareketli ortalama yöntemi: Hareketli ortalama yönteminde, Y değişkeninin bir sonraki dönemde alacağı tahmini değer, o değişkenin geçmiş n dönemdeki ortalaması alınarak bulunur. Matematiksel ifadesi Denklem (2.2)'de gösterilmektedir.

$$\hat{Y}_i = \frac{Y_{i-1} + Y_{i-2} + \dots + Y_{i-n}}{n} \quad (2.2)$$

Eğer belirli dönemlerin verileri (örneğin en yakın geçmiş dönemler) gelecek dönemler için kesin bir kanı veriyorsa, değerler hesaplanırken son dönemdeki verilere daha fazla ağırlık verilir.

Hareketli ortalamaya dahil edilecek gözlem sayısı, tahmini yapacak kişi tarafından belirlenir ve her zaman sabit kalmaktadır. Bu yöntem her yeni değer ile birlikte yeni bir ortalamaya sahip olur.

3. Ağırlıklı hareketli ortalamalar yöntemi: Bu yöntemde ürünün talebine etki eden dönemlere daha büyük ağırlıklar verilerek, bu dönemlerin ortalama daha fazla etkisinin olması sağlanabilir. Bunun yanı sıra zaman serisini oluşturan veriler arasında ortalamanın üstünde ve altında değerler varsa, bu değerlerin ağırlıkları düşürülerek tahmin değeri üzerindeki etkisinin azaltılması sağlanabilir. W ağırlık değerlerini, y ise gerçekleşen bağımsız değişken değerini göstermektedir. Ağırlıklı ortalama yönteminin formülasyonu yer almaktadır (Denklem 2.3).

$$\hat{Y} = \frac{w_1 * y_t + w_2 * y_{t-1} + \dots + w_n * y_{t-n+1}}{w_1 + w_2 + \dots + w_n} \quad (2.3)$$

Wn. n. dönemde gerçekleşen talebe verilen ağırlık olmak üzere verilecek olan ağırlıkların doğru belirlenmesi önemlidir. Bu değerler doğrusal olarak belirlenebilir. Bunun sonucunda geçmiş taleplere doğru düzgün bir azalış gösterecektir.

Hareketli ortalama yönteminde son kaç periyodun hesaplamaya dahil edileceği, tahmin edicinin kararına bağlıdır. Çoğunlukla deneme yanılma yöntemi ile belirlenir. Basit aritmetik hareketli ortalama yönteminde hesaplamaya dahil edilen son n dönemin değerleri eşit ağırlıklı idi. Bu iki durumun eksiklerini ortadan kaldırmak için aşağıdaki yöntem kullanılmaktadır.

a. Üssel ağırlıklandırılmış hareketli ortalama yöntemi: Bu yöntemde geçmiş zaman dönemlerine ait ortalama talep ile mevcut döneme ait talebi belirli oranlarda

tekrar ağırlandırarak bir sonraki dönemin talebini hesaplar. Metodun kullanılabilmesi için geçmiş dönemlerin talep ortalaması ve mevcut dönemin talep değeri yeterlidir. Bu yöntemle ait formülasyonlar aşağıdaki gibidir (Denklem 2.4 ve Denklem 2.5).

$$X = \frac{1}{\left(\frac{n}{2} - 1\right)} \quad (2.4)$$

$$\hat{Y} = \left[(1 - X) * \frac{\sum_{n=1}^{t-1} Y_n}{n} \right] + \left[(1-X) * Y_t \right] \quad (2.5)$$

X değeri en son dönemle önceki dönemler arasındaki ağırlıklandırmayı belirleyen katsayıdır. n dönem sayısını ve t ise ilgili dönemi ifade eder. Metot en son dönem ağırlığını önceki dönemlerden ayrı tutarak iki kez ağırlıklandırma yapar.

b. Üssel düzgünleştirme yöntemleri: Basit üssel düzgünleştirme yöntemi, holt lineer metodu, holt- winter mevsimlik tahmin yöntemi, box jenkins tahmin yöntemi, Otoregresif modeller - AR(p) modelleridir, hareketli ortalamalar, otoregresif hareketli ortalama ve otoregresif entegre hareketli ortalama yöntemleridir. Aşağıda bu yöntemler ayrıntılı olarak anlatılmıştır:

1. Basit üssel düzgünleştirme yöntemi: Bu yöntem geçmiş dönem verilerine eşit ağırlıkların verilmediği yöntemlerden biridir. Basit ve ağırlıklı hareketli ortalama yöntemlerinden farkı, bir döneme ilişkin tahmini talep miktarının bu dönemden önce gelen tüm dönemlerde gerçekleşmiş olan talep miktarlarına bağlı olarak belirlenmesini öngörmektedir [4].

Bir döneme ait talebi bulurken, bu dönemden önceki dönemlere ters orantılı ağırlıklar verir. Bu sayede en yakın geçmişte gerçekleşen talep miktarı, yapılan tahmini en fazla etkileyen veri olmaktadır. En geçmiş zamandaki talep miktarı ise, bulmak istediğimiz güncel talep miktarını en az etkileyen veri olmaktadır. Denklem (2.6)'da bu yöntemin formülasyonu yer almaktadır.

$$\hat{Y}_{t+1} = \hat{Y}_t + \alpha (y_t - \hat{Y}_t) \quad (2.6)$$

Bu formülde farklı olan α katsayısı 0 ile 1 arasında değer alan düzgünleştirme katsayısıdır. Bu katsayı dönemlere verilen ağırlık değerini etkilemektedir. α büyüdükçe son dönemlere daha çok ağırlık verilir. $(y_t - \hat{Y}_t)$ ifadesi bir önceki deneme ait tahminin hata değeridir. Eğer bu hata pozitif gerçekleşmişse, tahminden büyüktür ve düzgünleştirme bir sonraki değeri arttırıcı etki yapar. α değeri denemeler yapılarak en uygunu bulunur. Genellikle 0.05 ile 0.30 arasında seçilmelidir.

2. Holt lineer metodu: Bu yöntemi, zaman serisinin bir trende sahip olması durumunda geleceğe yönelik tahmin yapmak için kullanılabilir. Yöntem, Holt tarafından 1957 yılında, basit üssel düzgünleştirme yöntemine trend bileşeninin eklenmesiyle geliştirilmiştir.

3. Holt - winter mevsimlik tahmin yöntemi: Zaman serisinin trend bileşeni ile birlikte mevsimsellik de içerdiği durumlarda kullanılır. Bu durumda talep, doğrusal bir yapı göstermemektedir. Tahmin formülasyonunda trend bileşeni ile birlikte mevsimsellik bileşeni de vardır. Bu yöntemle ait formüller denklem (2.7), (2.8) ve (2.9)'da yer almaktadır.

$$\hat{Y}_t = \alpha y_t + (1-\alpha)(\hat{Y}_{t-1} + b_{t-1}) \quad (2.7)$$

$$b_t = \beta (\hat{Y}_t - \hat{Y}_{t-1}) + (1-\beta)b_{t-1} \quad (2.8)$$

$$Y_{t+m} = \hat{Y}_t + b_t m \quad (2.9)$$

Burada, ilk denklemde \hat{Y}_t değeri, Y_t değerine bir önceki dönemin trendi (b_{t-1}) ile bir önceki dönem düzgünleştirilmiş değerinin ilave edilmesiyle bulunmaktadır.

İkinci denklem son iki dönem düzeltme değerlerinin farkı şeklinde trendi güncellemektedir.

Son denklem ise y_{t+m} tahmini, bir önceki dönem düzgünleştirilmiş değerine (\hat{Y}_t) m kadar t dönemi trendinin (b_t) ilavesiyle yapılmaktadır. α ve β , düzeltme sabitleridir.

4. Box - Jenkins tahmin yöntemleri: Bu yöntem 1970 li yıllarda temelleri atılan, durağanlığı, deterministik bileşen bilgisini ve geleceğe ilişkin tahminleri bir arada ortaya koyduğu için tercih edilen bir yöntemdir.

Bu yöntemin, temelinde durağan olan ya da durağanlığı sağlanmış olan bir zaman serisine ilişkin birçok olası model arasında uygun ARIMA modelinin belirlenmesi, parametrelerin bulunması ve modelin uygunluğunun değerlendirilmesi olarak üç aşaması yer almaktadır. Kurulan model uygunluk testlerini geçemezse, aşamalar yeniden baştan başlatılır ve en iyi dereceyi veren modeli buluncaya kadar devam edilir. Bu bulunan model nihai model olarak adlandırılır ve tahminde bu model kullanılmaktadır. Bir değişkene ilişkin yapılacak tahmin, kendi gecikmeli değerleri, hata terimleri ya da her ikisinin birleşimi ile yapılmaktadır.

Bu yöntem ile bir zaman serisini modelleyebilmek için zaman serisinin durağan olması gerekmektedir. Bunun için, zaman serisinin ortalamasında ve varyansında sistematik bir değişim olmaması lazımdır. Eğer bir seri sabit bir büyüme ya da eğilim gösteriyorsa, bu yapıdaki seriler durağan hale dönüştürülmeden modelleme yapılamaz.

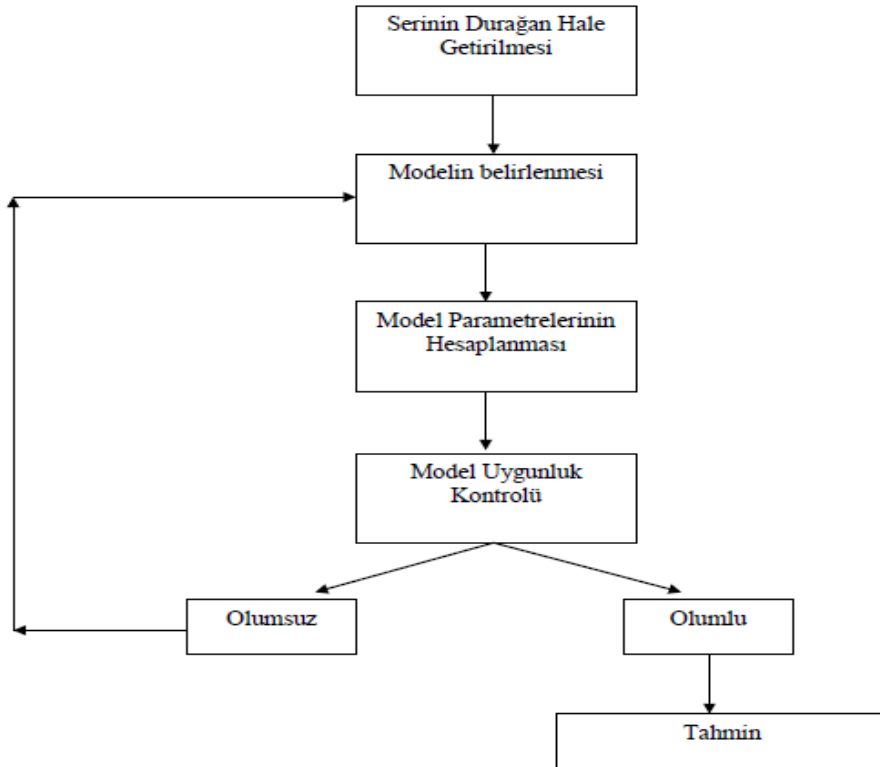
Bu yöntemde üç modelleme vardır: Bunlar Otoregresif (AR) Süreç, Hareketli Ortalama (MA) Süreci ve bunların birleşiminden oluşan Otoregresif Hareketli Ortalama (ARMA) Süreci'dir. Durağan olmayan bir seri için fark alınması gerektiğinde ise ARMA süreci yerine ARIMA süreci kullanılır. ARIMA Süreci, fark alınarak durağan hale getirilmiş otoregresif hareketli ortalama sürecini ifade etmektedir.

Box Jenkins yöntemi zaman serilerini kullanarak geleceği tahmin etmek için kullanılan tek değişkenli bir modeldir. Yöntemin en önemli varsayımı, eşit zaman aralıklarıyla yapılan gözlemlerden elde edilen serinin kesikli ve durağan olması gerektiğidir. Gözlem değerlerinin rastsal ve serinin de stokastik bir süreç olduğu varsayılır.

Bu yaklaşımda, model oluşturma ve tahmin genel olarak dört aşamada oluşmaktadır. Bunlar aşağıdaki gibidir:

1. Modelin belirlenmesi (identification): Zaman serisine uygun Box-Jenkins modeli bu aşamada belirlenir.
2. Modelin parametrelerinin kestirimi (estimation): Belirlenen modele ilişkin parametrelerin tahmin edildiği aşamadır.
3. Modelin uygunluğunun araştırılması (diagnostig checking): Modelin veri setine uygunluğunun istatistiksel yöntemlerle test edildiği aşamadır. Model uygun bulunursa bir sonraki aşamaya geçilir, uygun bulunmazsa ilk aşamaya yeni modelin belirlenmesine geri dönlür.
4. Tahmin (forecasting): Bulunan en uygun model tahmin için kullanılır.

Box Jenkins metolojisi Şekil 2.1.' deki gibi gösterilmektedir.



Şekil 2.1. Box jenkins metodolojisi [3]

5. Otoregresif modeller - $AR(p)$ modelleri: Bu modellerde, p değeri geçmiş dönem sayısını vermektedir. Model, p dönemdeki zaman serisi değerlerinin ağırlıklı

toplamının ve rassal hata değerinin bir fonksiyonudur. AR(p) modelinin genel olarak gösterimi aşağıdaki Denklem (2.10)'daki gibidir:

$$Y_t = \mu + \phi_1 * Y_{t-1} + \phi_2 * Y_{t-2} + \dots + \phi_p * Y_{t-p} + \epsilon \quad (2.10)$$

Formülde μ değeri serinin ortalamasını verir ve ϕ_1, \dots, ϕ_p otoregresif parametrelerini göstermektedir. ϵ değişkeni serinin hata değişkenini temsil eder.

6. Hareketli ortalamalar - MA (q) modelleri: Bu modelde, Y_t değeri serinin geriye doğru q dönem geçmiş hata terimlerinin ve ortalamasının doğrusal bir fonksiyonudur.

Bir değişkenin t dönemindeki değeri, aynı dönemdeki hata terimi (ϵ_t) ve hata teriminin önceki dönemlere ait gecikmeli değerleri ile belirlenir. Bu modelin genel gösterimi Denklem (2.11)'deki gibidir:

$$Y_t = \epsilon_t - \phi_1 * \epsilon_{t-1} - \phi_2 * \epsilon_{t-2} - \dots - \phi_q * \epsilon_{t-q} \quad (2.11)$$

Burada ϵ_t ler korelasyonsuz tesadüfi, sıfır ortalama ve sabit varyansa sahip hatalardır.

7. Otoregresif hareketli ortalama modeli ARMA (p,q): Bu model, AR ve MA modellerinin bir birleşimidir. Sadece AR veya sadece MA modelleri ile modelleyemeyen süreçlerde kullanılabilir. ARMA modelleri en genel durağan stokastik süreç olup, geçmiş gözlemlerin ve geçmiş hata terimlerinin doğrusal bir fonksiyonudur [4]. Formülasyonu gösterimi Denklem (2.12)'deki gibidir.

$$Y_t = \delta + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \epsilon_t + \phi_1 \epsilon_{t-1} + \dots + \phi_q \epsilon_{t-q} \quad (2.12)$$

Burada kesme terimi δ , Y_t nin ortalama ile ilgili hatalar ϵ_t olarak gösterilmektedir. Eğer bu süreç durağan ise tüm dönemler için sabit bir ortalamaya sahiptir [5].

8. Otoregresif entegre hareketli ortalama modeli ARIMA (p,d,q): Bu model, zaman serilerinin durağan olduğu varsayımına dayanır. Durağan olmayan fakat fark alma işlemiyle durağan hale dönüştürülmüş serilere uygulanan modellerdir. Birçok

durağan olmayan zaman serisi bir veya daha fazla fark alınarak, durağan zaman serisi haline dönüştürülür. D kere fark alınarak durağan hale getirilirse bu seriye durağan olmayan entegre süreç denilir.

Durağan bir zaman serisinde, ortalama, varyans ve otokorelasyon fonksiyonu sabittir. Zaman serileri durağan değilse, belirli bir trend içermektedir. Box Jenkins modellerinde uygun modelin belirlenmesi önemli bir süreçtir. Modelin belirlenmesi (p,d,q) parametrelerinin de belirlenmesi demektir. D değeri, serinin artan veya azalan yapısı varsa ve bu yapı doğrusal ise d=1, eğrisel ise d=2 alınır. Fakat p ve q değerleri otokorelasyon ve kısmi korelasyon fonksiyonları ile belirlenebilir. Bu modele ait formülasyonlar Denklem (2.13) ve Denklem (2.14)'de yer almaktadır.

$$m = \frac{\sum_{t=1}^T Y_t}{T} \quad (2.13)$$

$$\rho = \frac{\sum_{t=1}^{T-k} (Y_{t-m})(Y_{t-k-m})}{\sum_{t=1}^T (Y_{t-m})^2} \quad (2.14)$$

m değeri serinin ortalamasıdır. Korelasyon değeri (ρ) de k dönemin ilişkisini verir. Kısmi korelasyon ise, zaman serisindeki iki nokta arasındaki ilişkiyi belirler. Kısmi otokorelasyon, otokorelasyondan türetilir.

2.4.2.2. Nedensel yöntemler

Nedensel yöntemler, tahmin edilmek istenen etkeni, kendisini etkileyen faktörler ile ilişkilendirerek, tahminlerin bu faktörlerdeki değişimlere bağlı olarak yapılmasını amaçlayan yöntemlerdir. Talep ile talebi etkileyen etkenler arasında neden-sonuç ilişkisi vardır.

Nedensel yöntemlerde genellikle, bir değişkenin gelecekteki değeri tahmin edilmesinin dışında, bu değişkeni etkileyen faktörler arasındaki ilişkinin açıklanmasına çalışılmaktadır. Bağımlı değişken ile ilişkisi olan değişkenlerin belirlenmesi ve bu ilişkinin bir matematiksel modelinin bulunması amaçlanmaktadır.

Bu yöntemler arasında en çok tercih edilenleri, regresyon analizi ve korelasyon analizidir.

1. Regresyon analizi: Regresyon analizi bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi inceleyen bir yöntemdir. Eğer bağımsız değişken sayısı bir ise tek *değişkenli regresyon analizi*, birden fazla ise *çok değişkenli (çoklu) regresyon analizi* olarak adlandırılır.

Regresyon yönteminde çıktı Y_x , sistem girdileri ile X_1, X_2, \dots, X_n arasındaki ilişki incelenir. Burada Y_x bağımlı değişken, X_1, X_2, \dots, X_n ise bağımsız değişkenlerdir. Bu bağımsız ve bağımlı değişkenler arasındaki ilişki doğrusal veya eğrisel olabilmektedir.

Bağımsız değişkenler belirlendikten sonra, verilere dayanarak bağımlı değişken ile bağlantılarını açıklayan matematiksel model geliştirilir ve bu model ele alınan bağımlı değişkenin tahmini değerini bulmak için kullanılır.

Regresyon analizin en büyük özelliği, bu yöntemle geliştirilen modelin işletmenin karar mekanizmasına (yöneticilerine) çeşitli alternatif etkenlerin sonuç üzerinde değerlendirme yapma olanağı sağlamasıdır [6]. Bu nedenlerden regresyon analizi çoğu firmada kullanılmaktadır.

Tek değişkenli regresyon analizi: Tek değişkenli regresyon analizi bir bağımlı değişken ve bir bağımsız değişken arasındaki ilişkiyi inceler. Bu regresyon analizinde bağımlı ile bağımsız değişken arasında doğrusal bir ilişki vardır.

Çok değişkenli regresyon analizi: İçinde bir adet bağımlı değişken ve birden fazla bağımsız değişkenler arasındaki ilişkiyi inceler.

**Tek değişkenli regresyon modelinin formülasyonu Denklem (2.15)'deki gibidir:

$$Y_i = \beta_0 + \beta_i X_i + \epsilon_i \quad i=0,1,\dots,n \quad (2.15)$$

Bu formülde, Y_i tahmin değeri, X_i bağımsız değişkenin doğrusal bir fonksiyonu olarak gösterilmektedir. β_0 , doğrusunun Y eksenini kestiği noktayı, β_1 , doğrunun eğimini, ϵ_i ise i . gözleme ait hata bileşenini vermektedir. Burada β_0 ve β_1 değerleri, en küçük kareler yöntemi ile bulunmaktadır.

Gerçek uygulamalarda, β_0 ve β_1 değerleri bilinmiyorsa, ana kütlede örnekler alınarak bunların tahminçileri olan b_0 ve b_1 kullanılarak (2.16) no'lu denklem yazılır:

$$y = b_0 + b_1 * X_i + e \quad (2.16)$$

**Ana kütle ve örnek için çoklu regresyon denklemleri (2.17) ve (2.18) nolu denklemlerde gösterilmektedir.

$$Y_i = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_n X_n + \epsilon \quad (2.17)$$

$$Y = b_0 + b_1 X_1 + b_2 X_2 + b_n X_n + e \quad (2.18)$$


En küçük kareler yöntemine göre, bir zaman serisinde en iyi uyan başka bir deyişle bir değerler serisini en iyi ifade eden doğru veya eğri, geçmiş yıllara ait gerçek değerlerle formülün uygulanması ile bulunacak teorik değerler arasındaki farkların karelerinin toplamını (sapmaların kareleri toplamını) minimum yapan doğru veya eğridir [4].

En küçük kareler yönteminde, ϵ_i hata bileşeninin karesini minimum yapan doğru denkleminin bulunması amaçlanmaktadır. Bu denklemin bulunmasından sonra, sonraki dönemlerin tahmini yapılabilmektedir. β_0 ve β_1 değerleri aşağıdaki (2.19) ve (2.20) nolu denklemlerle bulunmaktadır:

$$\beta_1 = \frac{n \sum XY - (\sum X \sum Y)}{n \sum X^2 - (\sum X)^2} \quad (2.19)$$

$$\beta_0 = \frac{\sum Y}{N} - \beta_1 \frac{\sum X}{n} \quad (2.20)$$

β_0 ve β_1 değerleri kullanılarak gelecek dönemlere ait Y değerleri tahmin edilebilmektedir. Şekil 2.2.'de en küçük kareler yöntemine ait şekil yer almaktadır.



Şekil 2.2. En küçük kareler yöntemi [4]

2. Korelasyon yöntemi: Korelasyon analizi değişkenler arasındaki ilişkinin derecesini ortaya koymaktadır. Korelasyon bir değişkenin değeri değişirken diğer bir değişken bununla doğrusal ilişkili olarak değişiyorsa korelasyon vardır denilebilir. Korelasyon yöntemi, doğrunun uygunluğunu ölçmektedir. Başka bir ifadeyle, denklemin ilişkiyi ne ölçüde tanımladığını göstermektedir. İlişki ne derece güçlü ise, oluşturulan tahminlerde o derece iyidir.

Değişkenler arasındaki mevcut ilişkiyi betimlediği için betimleyici araştırmadır. Bir “korelasyon katsayısı” bularak aradaki ilişkiyi betimleyebiliriz.

Korelasyon katsayısı; iki değişken arasındaki doğrusal ilişkinin derecesini ölçen bir değer olup -1 ile +1 arasında değişir. r' nin -1 'e yakın olması, bu değişkenler arasında çok güçlü bir negatif doğrusal ilişki olduğunu, +1'e yakın olması da çok güçlü pozitif doğrusal ilişki olduğunu işaret eder. Mutlak değer olarak r' nin 0.7 den büyük olması doğrusal ilişkinin güçlü olduğu şeklinde bir yorum yapmamıza olanak verir. Eğer değişkenler arasında doğrusal bir ilişki yoksa R=0 çıkar.

Aşağıdaki Denklem (2.21)'de y ile x değerler beraber artıyorsa pozitif, x arttığında y düşüyorsa negatif bir değer alır. Sıfıra yakın bir korelasyon katsayısı ilişkinin zayıf, +1 e yakın katsayı ilişkinin kuvvetli pozitif, -1 e yakın korelasyon katsayısı ilişkinin kuvvetli negatif olduğunu gösterir [2]. Denklem (2.21)'de korelasyon katsayısının nasıl bulunduğu gösterilmiştir. R korelasyon katsayısını göstermektedir.

$$R = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{\sqrt{[n \sum X^2 - (\sum X)^2] [n \sum Y^2 - (\sum Y)^2]}} \quad (2.21)$$

Korelasyon katsayısının aldığı değerler aşağıdaki gibi yorumlanır [4].

0.90-1.00 : Çok yüksek korelasyon

0.70-0.90: Yüksek korelasyon

0.40-0.70: Normal korelasyon

0.20-0.40: Düşük korelasyon

0.00-0.20: Çok düşük korelasyon

2.4.2.3. Yapay zeka tabanlı yöntemler

Yapay zeka, insanın düşünme yapısını anlamak ve insan gibi düşünebilen bilgisayar işlemlerini geliştirme olarak tanımlanabilmektedir. Başka bir ifadeyle, insana özgü algılama, görme, düşünme, karar verme, bilgi edinme gibi özelliklere sahip olan bilgisayarlardır.

Yapay zeka tabanlı yöntemler, genellikle karmaşık problemlerin çözümünde güçlü yöntemler olarak bilinmektedir. Talep tahmininde en sık rastlanan yapay zeka yöntemleri, yapay sinir ağları, bulanık mantık ve genetik algoritmalarıdır. Bu çalışmada yapay sinir ağları kullanılmıştır.

1. Yapay sinir ağları: Yapay sinir ağları yapay zeka yöntemleri arasında en çok kullanılan yöntemlerden birisidir. Yapay sinir ağları örneklerden öğrenebilme ve genelleme yapabilme özelliklerine sahip olduğu için bu yönteme çok esnek ve güçlü

araçlar olma özelliği sağlamaktadır. 3. bölümde yapay sinir ağları konusu ayrıntılı olarak işlenecektir.

2. Bulanık mantık: Bulanık mantık kavramı ilk kez 1965 yılında Zadeh tarafından yapılan çalışmalar sonucunda ortaya atılmıştır. Bu çalışmalarında, girdi verilerinin farklı kümelerdeki farklı üyelik derecelerinden bahsetmiş ve girdinin çıktıya dönüşümünün bu kümeler aracılığıyla yapılabileceğinden söz etmiştir. Bu yöntem özellikle deneyimlere dayalı verilerin ya da sayısal olarak ifade edilemeyen verilerin yorumlanmasında yaygın olarak kullanılmaktadır [2].

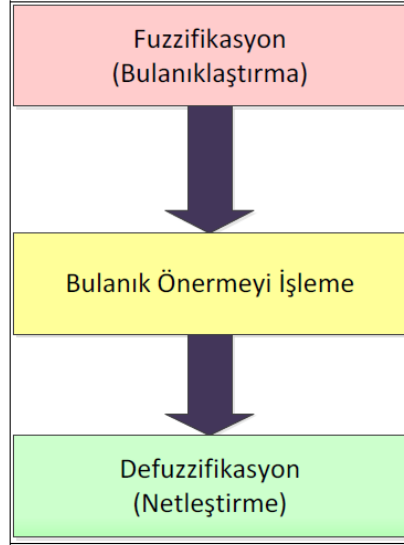
Bulanık küme, farklı üyelik derecesine sahip öğelerin olduğu bir kümedir. Bulanık küme, klasik küme teorisindeki evet-hayır olana ikili üyelik kavramını ikiden fazla kısmi üyelik içeren kavrama dönüştürmek anlamına gelmektedir.

Bir kavramı anlatan, bir amacı aktaran veya bir sistemi tanıtan ifadelerdeki belirsizliği veya kesin olmama haline bulanıklık denmektedir. İnsanların zihinsel düzeydeki algılama farklılıkları, onların subjektif davranışları, ifade ve amaçlarındaki belirsizlikler bulanıklık kavramı ile açıklanabilmektedir [6].

Bulanık mantığın özellikleri aşağıdaki gibidir:

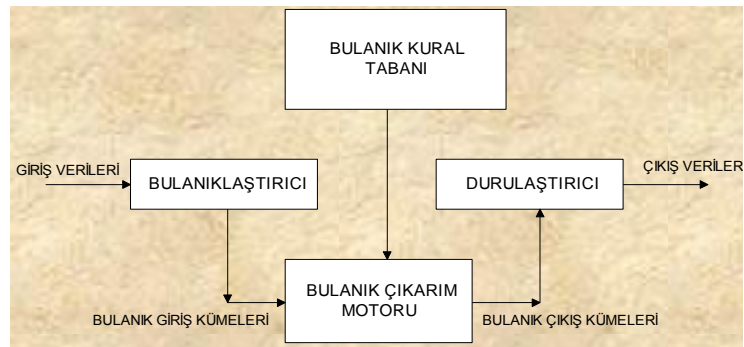
1. Bulanık mantık, kesin değerlere dayanan düşünme yerine, yaklaşık düşünme kullanır.
2. Bulanık mantıkta bilgi dilsel ifadeler (büyük, küçük vb.) şeklindedir.
3. Bulanık mantıkta her şey $[0,1]$ aralığında belirli bir derece ile gösterilir.
4. Bulanık çıkarım işlemi, dilsel ifadelerin birbirleri arasında tanımlanan kurallar ile gerçekleşir.
5. Mantıksal olan tüm sistemler, bulanık olarak ifade edilebilir.
6. Bulanık mantık, matematiksel modellerle elde edilmesi zor olan sistemler için oldukça uygundur [6].

Bulanık mantık süreci Şekil 2.3.' de gösterildiği gibidir:



Şekil 2.3. Bulanık mantığın elemanları ve çalışması [7]

Bulanıklaştırma işlemi, sistemden alınan giriş bilgilerini dilsel niteleyiciler olan sembolik değerlere dönüştürme işlemine denmektedir. Üyelik işlevinden yararlanılarak giriş bilgilerinin ait olduğu bulanık küme/kümeler ve üyelik derecesi tespit edilerek girilen değerler küçük, en küçük gibi dilsel değişkenler olarak atanmaktadır. Bulanıklaştırma, çözülecek problemle ilgili bulanık önerme değişkenlerinin ve karar verme kurallarının belirlenmesi ve üyelik fonksiyonunun oluşturulması işleminin adıdır. *Netleştirme işlemi*; bulunan çözüm alanından tek bir değer elde edilmesi işlemine denmektedir. Netleştirme yöntemlerinden bir tanesi kullanılarak kesin değer belirlenir.



Şekil 2.4. Bulanıklaştırma – netleştirme birimli bulanık sistem

3. Genetik algoritma: Genetik algoritmalar (GA) günlük hayatta karşılaştığımız çözümü olanaksız ya da çok zor olan karmaşık problemlerin hesaplanmasında kullanılmaktadır.

Genetik algoritmalar, doğal seçim ilkelerine dayanan bir arama ve optimizasyon yöntemi olarak ifade edilmektedir. Geleneksel optimizasyon yöntemlerine göre farklılıkları olan genetik algoritmalar, parametre kümesini değil, kodlanmış biçimlerini kullanır. Genetik algoritmalar; fonksiyon optimizasyonu, çizelgeleme, mekanik öğrenme, tasarım, hücresel üretim gibi alanlarda başarılı uygulamaları yapılmaktadır.

Genetik algoritmaların nasıl arama yaptığı alt dizi kavramıyla açıklanmaktadır. Alt diziler, genetik algoritmaların davranışlarını açıklamak için kullanılan teorik yapılardır. Bir alt dizi, belirli dizi kümeleri arasındaki benzerliği tanımlayan bir dizidir. Alt dizilerin iki özelliği vardır Bunlar; alt dizi derecesi ve alt dizi uzunluğudur. Alt dizi derecesi, mevcut alt dizi kalıbında bulunan sabit konumların sayısına denmektedir. Alt dizi uzunluğu ise; mevcut alt dizi kalıbında bulunan belirli ilk ve son konumlar arasındaki uzaklığa denmektedir. Alt dizi derecesi ve alt dizi uzunluğu kavramlar genetik algoritma temel teoreminde önemli bir yere sahiptir.

Genetik algoritmalar, bir çözüm uzayındaki her noktayı kromozom adı verilen ikili bit dizisi ile kodlamaktadır. Her noktanın bir uygunluk değeri bulunmaktadır. Tek bir nokta yerine genetik algoritmalar bir popülasyon olarak noktalar kümesini muhafaza etmektedir. Her kuşakta genetik algoritma, çaprazlama ve mutasyon gibi genetik faktörleri kullanarak yeni bir popülasyon oluşturur [36].

Genetik algoritmanın işlem adımları aşağıdaki gibidir:

1. Arama uzayındaki tüm mümkün çözümler dizi olarak kodlanır.
2. Genellikle rastsal bir çözüm kümesi seçilir ve başlangıç popülasyonu olarak kabul edilir.
3. Her bir dizi için bir uygunluk değeri hesaplanır, bulunan uygunluk değerleri dizilerin çözüm kalitesini gösterir.
4. Bir grup dizi belirli bir olasılık değerine göre rastsal olarak seçilip çoğalma işlemi gerçekleştirilir.
5. Yeni bireylerin uygunluk değerleri hesaplanarak, çaprazlama ve mutasyon işlemlerine tabi tutulur.

6. Önceden belirlenen kuşak sayısı boyunca yukarıdaki işlemler devam ettirilir.
7. İterasyon, belirlenen kuşak sayısına ulaşıncaya sona erdirilir. Amaç fonksiyonuna göre en uygun olan dizi seçilir.

Genetik algoritma tabanlı yaklaşım kullanılarak veri yığınlarından modeller elde edilmektedir. Talep tahmininin bulunmasında yararlanan bir yöntemdir.

2.5. Tahmin Yöntemlerinin Doğruluğunun Ölçülmesi

Tahmin yöntemlerinin hangisi kullanılırsa kullanılsın %100 doğru değeri vermez. Gelecek %100 biliniyorsa zaten bu tahmin olmaz. Bu nedenle her tahminde belirli bir hata oranı mevcuttur. Çeşitli tahmin modelleri arasında birini seçme sürecinde en yaygın kabul gören kriterlerden biri de modelin verilere uyum göstermesi, modelin öngörü başarısının yüksek olmasıdır. Modellerin öngörü başarılarının karşılaştırılması amacıyla çeşitli kriterler mevcuttur. Bu kriterlerden en önemlisi, tahmin doğruluğudur. Tahmin yönteminin doğruluğu, tahmin edilen hataların analiz edilmesiyle ölçülür. Tahmin hatası, gözlenen gerçek değerler ile tahmin edilen değerler arasındaki farktır. Herhangi bir periyottaki tahmin hatası Denklem (2.22)'de gösterilmektedir.

$$e_t = Y_t - F_t \quad (2.22)$$

Y_t : gözlenen gerçek değeri, F_t modelin ürettiği değeri göstermektedir. e_t değeri ise tahmin hatasını göstermektedir.

En çok kullanılan tahmin doğruluğu ölçüm kriterleri aşağıdaki gibidir:

1. *Ortalama hata kareleri (Mean Squared Error- MSE)*: Hata kareleri ortalaması, talep tahminlerinin doğruluk hesaplanmasında sıklıkla kullanılır. Bu yöntem hataları işaretlerden arındırır ve sadece büyüklüklerine bakar. Denklem (2.23)'de gösterilmektedir.

$$MSE = \frac{\sum(Y^T - Y^G)^2}{t-k} \quad (2.23)$$

Burada Y^T , tahminlenen değeri, Y^G ise gerçekleşen değeri göstermektedir. t , tahmin sayısını, k ise verilecek katsayıyı göstermektedir.

2. *Kök ortalama hata kare (Root Mean Squared Error – RMSE)*: Ortalama hata kareleri yöntemiyle bulunan hatanın karekökünün alınmasıyla bulunur. Denklem (2.24)'de yer almaktadır.

$$RMSE = \sqrt{\frac{\sum(Y^T - Y^G)^2}{t-k}} \quad (2.24)$$

3. *Ortalama mutlak hata (Mean Absolute Error – MAE)*: Bu yöntem, hata değerlerinin mutlak değerleri alınarak işaretlerden arındırılır. Böylelikle hata değerleri talep değerlerine uzaklıkları ile hesaplanmış olur. Denklem (2.25)'de gösterilmektedir.

$$MAE = \frac{\sum|Y^T - Y^G|}{t-k} \quad (2.25)$$

4. *Ortalama mutlak yüzde hata (Mean Percentage Absolute Error- MAPE)*: Bu yöntem, oluşan hataları yüzdesel olarak ifade eder. Böylelikle hataların birbirleri ile kıyaslanmasını sağlar. Denklem (2.26)'da gösterilmektedir.

$$MAPE = \sum \frac{|Y^T - Y^G|}{Y^G} \cdot \frac{100}{t} \quad (2.26)$$

5. *Kök ortalama yüzde hata kare (Mean Squared Percentage Error- MSPE)*: Kök ortalama yüzde hata kareleri ile ilgili formül Denklem (2.27)'de gösterilmektedir.

$$MSPE = \sqrt{\frac{1}{t-k} \sum \frac{(Y^T - Y^G)^2}{Y^G}} \quad (2.27)$$

Aşağıda formüllerde yer alan simgelerle ilgili açıklamalar mevcuttur:

t: Durağan hale getirilen serinin gözlem sayısı

k: Modelde tahmin edilen parametre sayısı

Y_T : Modelin tahmin değeri

Y_G : Serinin gerçek değeri

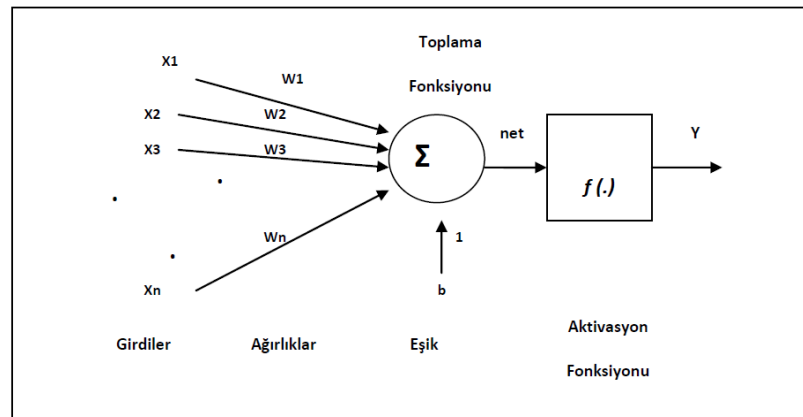
BÖLÜM 3. YAPAY SINIR AĞLARI İLE TALEP TAHMİNİ

Bu bölümde yapay sinir ağları ile ilgili temel kavramlar, ağ yapıları ve yapay sinir ağlarının eğitim algoritmaları anlatılmıştır.

3.1. Yapay Sinir Ağları İle İlgili Temel Kavramlar

Yapay sinir ağları (YSA) beyindeki sinirlerin çalışmasını taklit ederek öğrenme, genelleme yapma, hatırlama gibi yetenekler kazandırmayı amaçlayan bir bilgi işleme sistemidir.

YSA' nın çalışmasına esas teşkil eden en küçük birimler yapay sinir hücresi olarak adlandırılır. Şekil 3.1'de görüleceği üzere girdiler, ağırlıklar, birleştirme fonksiyonu, aktivasyon fonksiyonu ve çıkış olmak üzere beş ana bileşenden oluşmaktadır.



Şekil 3.1. Yapay Sinir Hücresi [9]

Yapay sinir ağları bir programcının yeteneklerini gerektirmeyen, kendi kendine öğrenme özelliğine sahip sistemlerdir. Bu ağlar öğrenme gibi yeteneklerinin yanı sıra, ezberleme ve bilgiler arasında ilişki kurma yeteneğine de sahiptirler. Yapay sinir ağlarının birçok çeşidi bulunmakla birlikte bunların bazılarının kullanımı diğerlerine

göre daha fazladır. Bunlardan bir tanesi geriye yayımlı yapay sinir ağı olarak bilinir. Bu tip ağlar özellikle tahmin ve sınıflandırma işlemlerinde başarılı sonuçlar verdiği görülmektedir [10].

Yapay sinir ağı, nöronların birbirleri ile ağırlıklar aracılığıyla çeşitli şekillerde bağlanmasından oluşmaktadır. Ağ ayrıca bu nöron bağlantılarının oluşturduğu katmanlar şeklinde sıralanmaktadır. Beynin öğrenme sürecine uygun olarak YSA, bir öğrenme algoritması eşliğinde kendisine sunulan veriyi derleme, bu verilerden bir çıkarım yapma, öğrenmiş olduğu bu çıkarımı nöronlar arasındaki ağırlıklar vasıtasıyla saklama ve bunu tüm veri uzayı için genelleme kabiliyetine sahip bir işlemci olarak gösterilebilir [11].

Yapay sinir ağları özellikle, sınıflandırma, modelleme ve tahmin uygulamaları olmak üzere pek çok alanda kullanılmaktadır. Yapılan uygulamalar incelendiğinde, YSA'ların çok boyutlu, gürültülü, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek sensör verilerinin bulunduğu ve problemi çözmek için matematiksel modelin ve algoritmalarının bulunmadığı durumlarda yaygın olarak kullanıldığı görülmektedir.

3.2. Yapay Sinir Ağları Genel Özellikleri

Yapay sinir ağlarının ortak özellikleri aşağıdaki gibidir:

1. *Doğrusal olmayan yapı:* Yapay sinir ağlarının en önemli özelliklerinden birisi, gerçek hayatta var olan doğrusal olmayan yapılarda da daha iyi sonuçlar vermesidir. Olayların bağlı olduğu parametrelerin tümü bilinse bile, parametreler arasındaki ilişkiler doğrusal olmayabilir. Doğrusal olmayan yapılarla karşılaşıldığında geleneksel lineer yöntemlerle çalışılması zordur. Bu nedenle, YSA doğrusal olmayan karmaşık problemlerin çözümünde kullanılan en önemli yöntemlerden biridir.
2. *Paralellik:* Yapay sinir ağlarında paralel işlemci kullanıldığından, yavaş bir birimin etkisi tüm sistemi yavaşlatmaz. Bu durum yapay sinir ağlarının daha hızlı ve güvenilir olduğu sonucunu doğurmaktadır. Geleneksel yöntemler

genellikle seri işlemlerden oluşur. Bu yöntemlerde seri bir işlem gerçekleşirken herhangi bir birimin yavaş olması tüm sistemi yavaşlatmaktadır.

3. *Öğrenme*: YSA'lar eğitilme veya başlangıç tecrübesi sayesinde veriyi kullanarak öğrenme yeteneğine sahiptir. Bu özelliği sayesinde geleneksel yöntemler ile çözülemeyen çok karmaşık problemlere çözüm sağlayabilmektedir.
4. *Dağıtılmış Hafıza*: Yapay sinir ağlarında bilgi, ağa yayılmış durumdadır ve hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir. Yapay sinir ağları, dağıtık bellekte bilgi saklayabilmektedir.
5. *Gerçek zamanlı işlem yapabilme*: Yapay sinir ağları paralel olarak işlem yapabileceklerinden gerçek zamanlı olarak çalışabilirler. Çünkü dağıtılmış paralel yapıları sayesinde, birim zamanda çok daha fazla veriyi işleyebilme kabiliyetine sahiptir.
6. *Genelleme*: Yapay sinir ağları, öğrenme yetenekleri sayesinde bilinen örnekler üzerinde öğrenerek, karşılaşılmamış durumlarla ilgili genelleme yapabilmektedir. Geleneksel yöntemlerin çoğu, eksik ve gürültülü bilgi ile çalışmamaktadır. Fakat YSA bu gibi durumlarda çok daha iyi performans gösterebilmektedir.
7. *Kendi ilişkisini oluşturma*: Yapay sinir ağları, verilere göre kendi ilişkilerini oluşturur ve denklem içermezler.
8. *Sınırsız sayıda değişken ve parametre*: Yapay sinir ağları, sınırsız sayıda değişken ve parametre ile çalışabilmektedir. YSA ile, sonsuz sayıda değişkeni, her biri sadece gerektiği anda, gerektiği kadar kullanabilecek şekilde eğitilebilmektedir [4].
9. *Dereceli bozulma*: Ağlar eksik bir problem ile karşılaştırıldıklarında hemen bozulmazlar. Hata toleransına sahip oldukları için dereceli bir şekilde bozulmaktadır [7].
10. *Bilginin saklanması*: Yapay sinir ağlarında, ağ bağlantılarının değerleri ölçülüp bu değerler bağlantılarda saklanmaktadır [25].
11. *Nümerik bilgi ile çalışma*: Yapay sinir ağları sadece nümerik bilgi ile çalışabilmektedir. Nümerik olmayan veriler, önce nümerik ifadeye çevrilir ve ağa gösterilir.

12. *Adaptasyon:* YSA tanımı veya parametreleri deęişen probleme ya da sisteme uygun çözümler sağlamak için tekrar tekrar eğitilebilir. Bu özellik YSA'nın hedef tanıma, uyarlamalı örnek tanıma, sınıflandırma, işaret işleme, otomatik kontrol ve sistem kimliklendirme ve modelleme gibi alanlarda kullanımını yaygınlaştırmıştır [18].

3.3. Yapay Sinir Ağlarının Tarihsel Gelişimi

İlk yapay sinir ağı çalışmasına, nörolog Warren McCulloch ve bir bilim adamı Walter Pitts tarafından 1943 yılında insan beyninin hesaplama yeteneğinden esinlenerek elektrik devreleriyle basit bir sinir ağı modelleyerek başlanmıştır.

1949 yılında Hebb, "Davranış Organizasyonu" isimli kitabında, öğrenme ile ilgili temel teoriyi işlemiştir. Hebb tarafından geliştirilen kural Hebbian öğrenme kuralı olarak adlandırılmaktadır. Bu kural, yapay sinir ağının bağlantı sayısı deęiştirildiğinde öğrenmenin olabileceğini öngörmektedir [7].

1954 yılında Farley ve Clark, rassal ağlar ile adaptif tepki üretme terimlerini ortaya koymuştur. Bu kavram 1958 yılında Rosenblatt ve 1961 yılında Caimiello tarafından geliştirilmiştir [12].

Özellikle Rosenblatt (1958) tarafından geliştirilen "Perceptron" yapay sinir ağlarındaki çalışmalar hızlandırmıştır. Perceptron (algılayıcı), örüntü (şekil) tanıma amacıyla geliştirilen tek katmanlı, eğitilebilen ve tek çıkışa sahip olan bir yapay sinir ağıdır. Perceptron'un daha sonra geliştirilecek ve yapay sinir ağları çalışmalarında devrim kabul edilen çok katmanlı sinir ağlarının temelini oluşturması açısından tarihsel önemi de vardır [4].

1959 yılında Widrow ve Hoff, ADALINE (Adaptive Linear Neuron) modelini ortaya koymuşlardır. YSA'nın mühendislik uygulamalarında kullanılmasına başlanmasında atılan ilk adımlardan birini oluşturmaktadır. 1970'lerin sonlarında ADALINE modelinin çok katmanlı hali olan MADALINE'nin temelini oluşturmaktadır [7].

MADALINE modeli ise, telefon hatlarında oluşan yankıları yok eden bir uyarlanabilir süzgeç olarak adlandırılmaktadır [12].

1960'lı yılların sonunda iki matematikçi Minsky ve Papert, yazdıkları "Perceptrons" isimli kitaplarında algılayıcıların doğrusal olmayan problemlere çözüm üretemediklerini ortaya koymuşlardır. YSA'nın XOR problemini çözemediğini kanıtlamalarıyla bu alanda yapılan çalışmalarda duraklama yaşanmıştır. Birçok araştırmacının YSA'ya olan güveni sarsılmış ve yatırımlar yarıda bırakılmıştır. Amerika Birleşik Devletleri'nde araştırma geliştirme çalışmalarını yürüten organizasyon olan DARPA, YSA ile ilgili çalışmalarını desteklemeyi durdurmuştur [7].

1982 yılında Hopfield özellikle geleneksel bilgisayar programlama ile zor olan XOR problemlerini, çok katmanlı algılayıcılar ile çözmüştür. Bu çalışmaların pratikte uygulanabilir olması YSA'ya olan ilgiyi yeniden arttırmıştır. Hopfield, tekli algılayıcılar ile çözülemeyen XOR problemlerini çok katmanlı algılayıcılar ile çözerek YSA'nın işe yaramadığını söyleyen bütün tezlerin çürütülmesine yol açmıştır.

1986 yılında Rumelhart ve arkadaşları tarafından YSA için geriye yayılma algoritması geliştirilmiştir. Bu algoritma YSA'da yaygın olarak kullanılan algoritmalardan biridir. Birden çok katmanlı ağların, tek katmanlı ağların çözemeyeceği XOR problemini geriye yayılım algoritması ile çözmüşlerdir.

1988'de Broomhead ve Lowe, radyal tabanlı fonksiyonlar (RBF) modelini geliştirmişlerdir. Bu ağın çok katmanlı algılayıcılara alternatif bir ağ olduğunu belirtmişlerdir. Radyal tabanlı ağlar, özellikle filtreleme ve veri sıkıştırma problemlerinde kullanılmaktadır.

1990'da Spetch, Olasılıksal Sinir Ağlarını (Probabilistic Neural Network) geliştirmiştir. Olasılıksal sinir ağları, radyal tabanlı fonksiyonların daha gelişmiş şeklidir. Bu çalışmalarından sonra Spetch 1991'de Genelleştirilmiş Regresyon Ağlarını (RNN) geliştirdi.

Günümüzde YSA, diğer yapay zeka teknikleriyle birlikte (bulanık mantık, genetik algoritma) daha etkili çözümler sunmaktadır. Özellikle sınıflandırma, tahmin, örüntü tanıma gibi konularda yapay sinir ağları çoğunlukla olarak kullanılmaktadır.

3.4. Yapay Sinir Ağlarının Avantajları

Yapay sinir ağları, özellikleri ve yapısı sayesinde birçok önemli avantajları vardır. Gerçek dünyada açıkça görülemeyen ilişkileri geleneksel yöntemlerle çözmek mümkün olmayabilir. Bu gibi durumlarda YSA ile çözüme ulaşılabilmektedir. YSA örneklerden öğrenebilme ve eksik bilgi ile çalışabilme özelliği ile örnekler yardımıyla kendi kendine öğrenir. YSA'nın avantajları aşağıdaki gibidir:

1. Yapay sinir ağları, problemi çözerken diğer geleneksel hesaplama yöntemlerine göre zamanı daha verimli kullanır.
2. Yapay sinir ağları, örnekler yardımıyla öğrenir ve kendisini geliştirir. YSA'nın bir problemi öğrenmesi için problemin giriş verilerine karşılık çıkış verilerinin veya sadece giriş verilerinin sağlanması gerekir. Giriş ve çıkış verileri ile tanımlanan öğrenme kümesi yeteri sayıda örnek içermeli ve YSA'nın yapısına uygun düzenlenmiş olması lazımdır.
3. Yapay sinir ağları doğrusal olmayan yapıya sahip oldukları için, gerçek hayattaki problemlere daha optimal çözebilmektedir.
4. Yapay sinir ağları değişen bir ortamda esnekliğe sahiptir.
5. Şekil tanıma, genelleme, sınıflandırma ve ilişkilendirme konularında güçlü bir yöntemdir. YSA, eğitim sürecinin ardından, eğitim kümesi dışındaki veriler için de çıkış verileri üretir. Test verileri ile bu çıkışlar test edilir. Eğer bu çıkış değerleri kabul edilebilir hata değeri içerisinde ise, YSA genelleme yapabilmektedir.
6. YSA, yeni bilgilerin ortaya çıkması ve sistemde bazı değişikliklerin olması durumunda yeniden eğitilebilirler [9].
7. YSA, eksik bilgi ile çalışabilmektedir ve ayrıca belirsiz bilgileri işleyebilme özelliğine sahiptir.

8. YSA'nın hata toleransına sahip olması nedeniyle, ağın herhangi bir hücresinin bozulması ağın tümünü etkilememektedir. Fakat ağın bozuk olan hücresinin etkisine göre, ağın performansında azalma olabilmektedir.
9. YSA'lar paralel çalışabildikleri için, günlük yaşamda gerçek zamanlı olarak kullanımları daha kolaydır.

3.5. Yapay Sinir Ağlarının Dezavantajları

YSA'nın belirtilen avantajlarına karşılık aşağıdaki dezavantajları da vardır:

1. YSA'da ağın yapısının oluşturulması, modelin seçilmesinde belli bir kural yoktur. Genellikle deneme yanılma yöntemiyle kullanıcının tecrübesine ve sezgilerine bağlı olarak yapılmaktadır. Bu şekilde yapılması önemli bir problemdir. Çünkü problem için uygun bir ağ oluşturulamazsa problemin çözümünden istenen sonuç alınamayabilir ve ağa duyulacak güven azalır.
2. Uygun çözüme her zaman ulaşamayabilmeyebilir.
3. YSA'lar paralel çalışabilme özelliği yüzünden bir donanıma bağımlı olarak çalışırlar ve bu da önemli bir sorundur.
4. Ağın eğitimine ne zaman son verileceği ile ilgili kesin belirli bir yöntem yoktur.
5. Bazı ağlarda, ağın parametre değerlerinin nasıl belirleneceği ile ilgili bir kural yoktur.
6. Kullanılacak öğrenme algoritmasının YSA yapısına uygun belirlenemeyebilir.
7. Ağın davranışları açıklanamaz.

3.6. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

3.6.1. Biyolojik sinir hücresi

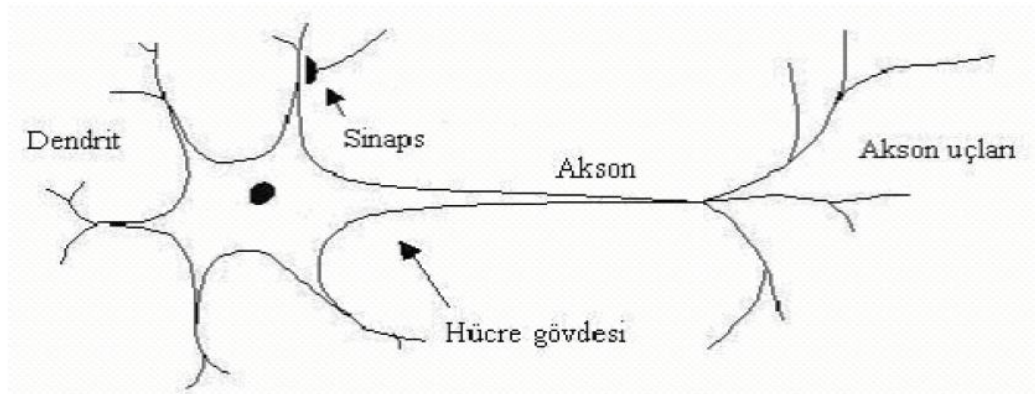
Biyolojik sinir ağları, beynimizde bulunan birçok sinir hücresinin birleşiminden oluşmaktadır. Bir sinir ağı milyarlarca sinir hücresinin bir araya gelmesiyle

oluşmaktadır. Beynimizde 10^{10} adet sinir hücresi ve bunların 6×10^{13} ten fazla sayıda bağlantısının olduğu söylenmektedir.

Biyolojik sinir ağları, insan beyninin çalışmasını sağlayan en temel taşlardan birisidir. İnsanın bütün davranışlarını ve çevresini anlamasını sağlar. Biyolojik sinir ağları beş duyu organından gelen bilgiler ışığında geliştirdiği algılama ve anlama mekanizmalarını çalıştırarak olaylar arasındaki ilişkileri öğrenmektedir [9].

Biyolojik sinir hücresi, beyin merkez olmak üzere üç katmandan oluşmaktadır. Bu katmanlar; çevreden gelen sinyalleri elektriksel sinyallere çeviren alıcı sinirler, beyin ürettiği sinyalleri uygun tepkilere dönüştüren tepki sinirleri ve tepki sinirleri arasında sürekli ileri geri besleme yaparak uygun sinyaller üreten merkezi sinir sisteminden oluşmaktadır [13]. Sinir sisteminin temel elemanları nöronlardır. Nöronlar; dendritler, hücre gövdesi, aksonlar ve sinaplardan oluşur.

Sinir hücresi, dendrit adı verilen uzantılarla diğer sinir hücresinden aldığı işaretleri hücre gövdesine taşır ve hücre gövdesinde toplanan bu işaretler değerlendirilerek bir çıkış işareti üretilir ve bu işaretler aksonlar aracılığıyla diğer sinir hücresine gönderilmektedir. Bir sinir hücresinden birden çok giriş olmasına rağmen sadece tek bir çıkış vardır. İki sinir hücresinde, birinin çıkış elemanı olan akson ile diğer sinir hücresinin giriş elemanı dendriti arasında olan bağlantıya sinaps adı verilmektedir ve sinapstik bağ oluşturmaktadır. Vücut içerisinde yer alan milyarlarca sinir hücresi sinapstik bağlarla birbirlerine bağlanarak sinir ağını oluşturmaktadır. Şekil 3.2.'de biyolojik sinir hücresi yer almaktadır.



Şekil 3.2. Biyolojik sinir hücresi [13]

Sinir hücrelerinin bazı özellikleri aşağıdaki gibidir:

1. Bir nöronun belirli bir aksonu olmayabilir ve bu nöron sadece bilgi alış verişinin işlenmesini sağlayabilir.
2. Aksonlar diğer aksonlarla sinaps oluşturabilir.
3. Dendritler diğer dendritlerle sinaps oluşturabilir.

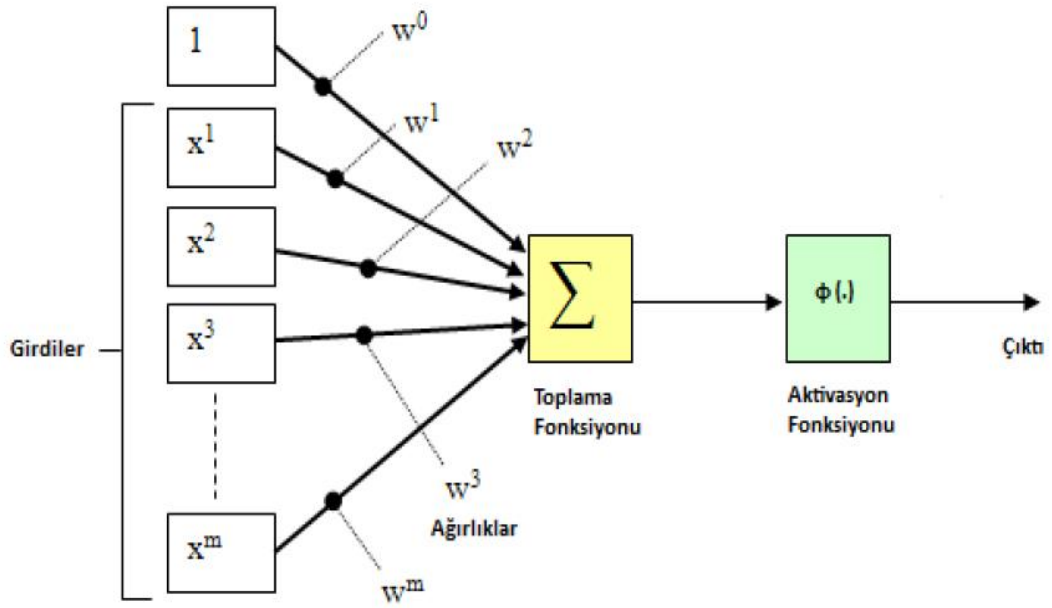
3.6.2. Yapay sinir hücresi

Yapay sinir ağları, biyolojik sinir ağına benzer şekilde, belirli bir performans özelliğine sahip ve insan beyninin çalışma prensibini örnek alan bilgi işleme sistemleridir. Biyolojik sinir hücresi ile yapay sinir hücresi arasındaki benzerlikle Tablo 3.1.'de verilmiştir.

Tablo 3.1. Biyolojik sinir hücresi ve YSA benzeşimleri [18]

Biyolojik Sinir Sistemi	YSA
Nöron	İşlemci eleman
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Aksonlar	Yapay nöron çıkışı
Sinapslar	Ağırlıklar

YSA'lar birbirine bağlı doğrusal ve/veya doğrusal olmayan birçok elemandan oluşurlar. Bir yapay nöron temel olarak girişler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıkış olmak üzere beş kısımdan oluşmaktadır. Şekil 3.3.'de bir yapay sinir hücresi verilmiştir.



Şekil 3.3. Yapay Sinir Hücresi Gösterimi [15]

3.6.2.1. Girdiler

Girdiler (x_1, x_2, \dots, x_n) çevreden aldığı bilgiyi sinir hücresine getiren öğelerdir. Kendinden önceki sinirlerden veya doğrudan dış dünyadan sinir ağına giriş olarak gelebilmektedirler.

3.6.2.2. Ağırlıklar

Ağırlıklar (w_1, w_2, \dots, w_n), yapay sinir hücresi tarafından alınan girişlerin sinir üzerindeki etkisini belirleyen katsayılardır. Her bir giriş kendine ait bir ağırlığa sahiptir [15].

3.6.2.3. Toplama fonksiyonu

Bir hücreye gelen net girdi, toplama fonksiyonu ile hesaplanmaktadır. Toplama fonksiyonu olarak çok farklı fonksiyonlar kullanılabilir ama en yaygın olanı ağırlıklı toplamı bulma fonksiyonudur. Bu fonksiyonda, her gelen girdi değeri kendi ağırlığı ile çarpılmaktadır ve tüm girdiler için bulunan bu değerlerin toplamı alınmaktadır. Formülasyonu Denklem (3.1.)'de yer almaktadır.

$$NET = \sum_i^n G_i A_i \quad (3.1)$$

G: Girdileri

A: Ağırlıkları

n: Hücreye gelen toplam girdi sayısını gösterir.

Tablo 3.2. Toplama fonksiyonun türleri [11]

Net Giriş	Açıklama
<p><i>Çarpım</i></p> $Net\ Girdi = \prod_i G_i A_i$	Ağırlık değerleri ile girdi değerlerinin birbirleriyle çarpılmasıyla elde edilir.
<p><i>Maksimum</i></p> $Net\ Girdi = Max(G_i A_i), i = 1 \dots N$	Ağırlıklar ile girdiler çarpılır, çarpılmış değerler birbirleri ile kıyaslanır ve en büyük olan değer sistemin net girdisi olur.
<p><i>Minimum</i></p> $Net\ Girdi = Min(G_i A_i), i = 1 \dots N$	Ağırlıklar ile girdiler çarpılır, çarpılmış değerler birbirleri ile kıyaslanır ve en küçük olan değer sistemin net girdisi olur.
<p><i>Çoğunluk</i></p> $Net\ Girdi = \sum_i sgn(G_i A_i)$	Ağırlıklarla çarpılmış olan girdilerin işaret fonksiyonu alınır, bu değerler toplanır ve net girdi olarak sisteme sunulur.
<p><i>Kümülatif Toplam</i></p> $NET\ Girdi = Net(eksi) + \sum_i^n G_i A_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.

3.6.2.4. Aktivasyon fonksiyonu

Aktivasyon fonksiyonu, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirleyen fonksiyondur. Yapay sinir hücresinin çıktısının büyüklüğünü sınırlandıran fonksiyon olarak da bilinmektedir. Bazı kaynaklarda eşik

değer, transfer veya sıkıştırma fonksiyonu olarak da isimlendirilir. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da değişik formüller kullanılmaktadır. Doğrusal fonksiyonların tercih edilmesinin nedeni, doğrusal fonksiyonlarda girdi ile çıktının doğru orantılı olmasından kaynaklanmaktadır. Bu durum ilk yapay sinir ağları denemelerinin başarısızlıkla sonuçlanmasının temel nedenlerinden birisidir [4].

Yine toplama fonksiyonunda olduğu gibi, her proses elemanı aynı toplama fonksiyonuna sahip olabileceği gibi, farklı toplama fonksiyonuna da sahip olabilmektedir. Bu durum tamamen tasarımcının öngörüsüne ve yaptığı denemelerin sonucuna bağlı olarak gerçekleşmektedir. Sonuç olarak uygun fonksiyonu gösteren bir formül yoktur.


Aktivasyon fonksiyonunun doğru seçilmesi, ağı performansını etkileyen bir unsurdur. Seçilen aktivasyon fonksiyonu doğrusal değilse, eğim parametresinin belirlenmesi lazımdır. Eğim parametresi, uygun sonuca yeterli derecede ulaşmasında rol oynayan önemli bir faktördür [21].

Günümüzde çoğunlukla aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmaktadır. Sigmoid fonksiyonu doğrusal olmayan problemlerin çözümünde kullanılan YSA'larda tercih edilmesi ile birlikte türev bilgisine ihtiyaç duyan algoritmalar için de avantaj sağlar.

Bu fonksiyon sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmadığından YSA'da sıklıkla kullanılır. Bu fonksiyon girdi değerlerinin her biri için sıfır ile bir arasında bir değer üretir. Fonksiyonunun gösterimi Denklem (3.2)'deki gibidir:

$$F(\text{NET}) = \frac{1}{1+e^{-\text{NET}}} \quad (3.2)$$

Burada NET, proses elemanına gelen net girdi değerini gösterir. Bu değer toplama fonksiyonu kullanılarak belirlenir.



Şekil 3.4. Sigmoid fonksiyonunun şekilsel gösterimi [4]

Literatürde en sık karşılaşılan aktivasyon fonksiyonları Tablo 3.3.'deki gibidir.

Tablo 3.3. Bazı aktivasyon fonksiyonları [9]

Fonksiyon Türü	Fonksiyon	Fonksiyonun Grafiği
Lineer (Doğrusal) Fonksiyon	$F(NET) = NET$	
Hiperbolik Tanjant Fonksiyonu	$F(NET) = \frac{e^{NET} + e^{-NET}}{e^{NET} - e^{-NET}}$	
Sigmoid Fonksiyonu	$F(NET) = \frac{1}{1 + e^{-NET}}$	
Eşik (Basamak) Fonksiyonu	$F(NET) = \begin{cases} 1, & NET > t \\ 0, & NET \leq t \end{cases}$	

Yukarıdaki tabloda yer alan transfer fonksiyonlarının genel özellikleri aşağıdaki gibidir:

1. *Lineer (doğrusal)* aktivasyon fonksiyonunda gelen girdiler, olduğu gibi hücrenin çıktısıdır.
2. *Hiperbolik tanjant* aktivasyon fonksiyonunda hücre çıktısı gelen NET girdi değerinin tanjant fonksiyonundan geçirilmesi ile bulunur. $[-1,1]$ aralığında çıktı değeri üretir.
3. *Sigmoid* aktivasyon fonksiyonunda YSA'da en çok kullanılan aktivasyon fonksiyonudur. Doğrusal ve doğrusal olmayan davranışlar arasında denge sağlayan ve sürekli artan bir fonksiyondur. Türevi alınabildiği için geri yayılım algoritmasında yaygın olarak kullanılır. Hücrenin çıktı değeri $[0,1]$ aralığındadır.
4. *Eşik (basamak)* aktivasyon fonksiyonu çoğunlukla tek katmanlı ağlarda kullanılır. Hücrenin çıktı değeri $[0,1]$ aralığındadır.

Toplama fonksiyonundan çıkan veri toplam hücrenin çıktısını oluşturmak için aktivasyon fonksiyonuna iletilir. Aktivasyon fonksiyonu olarak ise çoğunlukla doğrusal olmayan bir fonksiyon seçilir. Yapay sinir ağlarının bir özelliği olan “doğrusal olmama” aktivasyon fonksiyonlarının doğrusal olmama özelliğinden gelmektedir. Aktivasyon fonksiyonu seçilirken, türevi kolay hesaplanabilen bir fonksiyon seçilmesine dikkat edilmesi gerekmektedir [2].

3.6.2.5. Çıktılar

Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Bu değer ya başka bir yapay sinir hücresine girdi olarak ya da dış ortama gönderilir. Bir YSA hücresinin birden fazla girdisi olmasına rağmen tek bir çıktısı vardır.

3.7. Yapay Sinir Ağları Modelleri


Yapay sinir ağları sinir ya da düğüm adı verilen işlem elemanlarının bir araya gelmesinden oluşmaktadır. Yapay sinir ağı modelleri, sinirler arasındaki bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönüne göre birbirinden ayrılmaktadır. Bu modeller ileri beslemeli ve geri beslemeli olarak ikiye ayrılır [1].

3.7.1. İleri beslemeli ağlar

İleri beslemeli ağlarda, işlem genellikle katmanlara ayrılmıştır ve hücreler katmanlar halinde düzenlenmektedir. İşlemci elemanlar, bir katmandan diğer bir katmandaki tüm işlem elemanlarıyla bağlantı kurarlar ancak işlem elemanlarının aynı katman içerisinde kendi aralarında bağlantıları bulunmamaktadır. Bir katmanda bulunan hücrelerin çıkışları ağırlıklar üzerinden sonraki katmana giriş olarak aktarılmaktadır. Dış ortamdan alınan hücreler hiçbir değişikliğe uğramadan gizli katmandaki hücrelere iletilmektedir.

Orta ve çıkış katmanında işlenen bilgi ağ çıkışı olarak belirlenmektedir. İleri beslemeli ağlarda bilgi akışı, girdi katmanından gizli katmana, gizli katmandan da çıktı katmanına doğru iletilmektedir. Bu akış geri besleme yapılmadan tek yönlü olarak yapılmaktadır. Bir katmandaki yapay sinir hücreleri, bir önceki YSA hücreleri tarafından beslenir.

Bu yapay sinir ağları katman sayısına göre tek ve çok katmanlı ileri beslemeli yapay sinir ağları olarak sınıflandırılabilir. Genellikle sinyal işleme, nesne tanıma, sistemlerin tanımlanması ve denetimi vb. alanlarda yaygın olarak kullanılmaktadır. İleri beslemeli ağ şeması Şekil 3.5.'te verilmiştir.



Şekil 3.5. İleri beslemeli nöron ağı [10]

İleri beslemeli ağlarda gecikmeler yoktur ve işlem girişlerden çıkışlara doğru ilerler. Çıkış değerleri öğreticiden alınan istenen çıkış değerleriyle karşılaştırılıp bir hata sinyali elde edilir ve ağ ağırlıkları yeniden güncellenir.

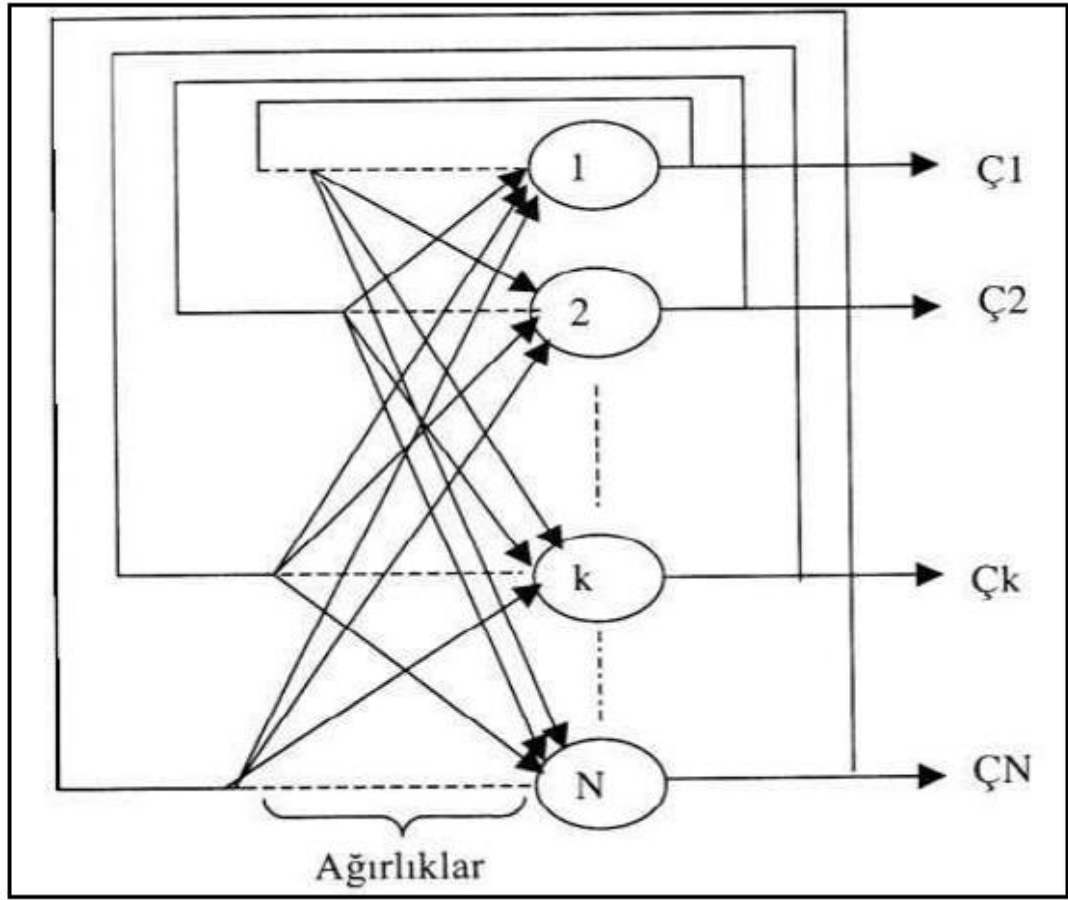
Gizli katmanındaki nöronların doğrusal olmayan davranışlarından dolayı, ağın toplam davranışı da doğrusal olmamaktadır. Ağı oluşturan giriş ve çıkış katmanlarındaki nöron sayısı problemin yapısına göre belirlenebilir. Gizli katmanın yapısını belirlemede analitik bir yöntem bulunmamaktadır. Kişisel tecrübe ve deneme yanılma yöntemi ile uygun çözüm bulunmaya çalışılır.

3.7.2. Geri beslemeli ağlar

Bu ağ yapısında, en az bir hücrenin çıkışı kendisine ya da diğer hücreler giriş olarak verilir ve genellikle geri besleme bir geciktirme elemanı sayesinde yapılmaktadır. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Bu özelliğinden dolayı, doğrusal olmayan dinamik bir davranış göstermektedir [1].

Yayıma ve uyum gösterme olmak üzere iki aşamada işlemleri gerçekleştiren standart geri besleme algoritması, katmanlar arasında tam bir bağlantının bulunduğu çok katmanlı, ileri beslemeli ve öğreticili olarak eğitilen bir YSA modelidir.

Standart geri besleme algoritması, hataları geriye doğru çıkıştan girişe azaltmaya çalıştığından dolayı bir ismi alır. Bu geri beslemeli ağ modelinde giriş, gizli ve çıkış olmak üzere üç katman bulunmaktadır fakat problemin özelliklerine göre gizli katman sayısı arttırılabilir. Geri beslemeli ağ Şekil 3.6.'da gösterilmektedir.



Şekil 3.6. Geri beslemeli YSA [1]

3.8. Yapay Sinir Ağlarında Öğrenme Algoritmaları

Yapay sinir ağlarında en ayırt edici özellik öğrenme yeteneğidir. YSA'da öğrenme, istenen bir işlevi yerine getirecek bir şekilde ağırlıkların ayarlanması ile yapılmaktadır. Ağırlıkların ayarlanması, probleme ait örnekler yardımı ile yapılmaktadır. Ağ, gördüğü her örnek problem için ağırlıklarını değiştirir. Bu işlem ağın doğru ağırlık değerlerine ulaşması, başka bir ifadeyle, örneklerin temsil ettiği olayla ilgili genelleme yapabilecek duruma gelmesi ile sonuçlanmaktadır. Ağırlıkların değiştirilmesi, kullanılacak olan öğrenme stratejisine ve öğrenme kuralları ile yapılmaktadır.

YSA'da öğrenme esnasında elde ettiği bilgiler, sinir hücreleri arasındaki bağlantı ağırlıklarında saklanmaktadır. Bu ağırlık değerleri yapay sinir ağının verileri başarılı bir şekilde işleyebilmesi için gerekli olan bilgileri içermektedir. Öğrenmedeki en

önemli noktalardan birisi, öğrenmeyi sağlayacak olan eğitim kümesinin seçilmesidir. Eğitim kümesi, en az bilgi ile en iyi öğrenmeyi sağlayacak şekilde seçilmelidir [15].

YSA' da öğrenme kuralı, Hebbian öğrenme kuralı denilen basit bir modele dayanmaktadır. Bu kuralın temeli olarak, iki düğüm aynı zamanda etkin ise, aralarındaki bağ gücünün arttığı yatmaktadır.

İnsan beyni de doğumdan sonraki gelişme sürecinde çevresinden duyu organlarıyla algıladığı davranışları yorumlar ve bu bilgileri diğer davranışlarında kullanır. Yaşadıkça beyin gelişir ve tecrübe kazanır. Artık olaylar karşısında nasıl tepki göstereceğini bilir. Fakat daha önceden hiç karşılaşmamış olduğu bir olay karşısında tecrübesiz kalır. YSA'da öğrenme sürecinde tıpkı bu şekilde dış ortamdan girişleri alır. Bu girişlerin beyin merkezine iletilerek burada değerlendirilip tepki verilmesi gibi YSA'da aktivasyon fonksiyonundan geçirilerek bir tepki çıkışı verir. Bu çıkış gene tecrübeyle verilen çıkışla karşılaştırılarak hata bulunmaktadır. Çeşitli öğrenme algoritmalarıyla hata azaltılıp gerçek çıkışa yaklaşılmaya çalışılmaktadır. Bu süreçte, ağırlıklar yenilenir. Ağırlıklar her çevrimde yenilenerek amaca ulaşılmaya çalışılır [3]. YSA'larda öğrenme tıpkı bir bebeğin beyninin öğrenmesi gibi deneme yanılmayla, hata yaparak olmaktadır. Buradaki amaç bulunması gereken sonuçlara en yakın sonucu bulmaktır. Bulunması gereken sonuç ile ağın ürettiği sonuç arasındaki fark olan hatayı, kabul edilebilir düzeye indirmek için sürekli bu işlemler tekrarlanmaktadır. Bu işlemlerden her birine devir (epoch) denir. Devir sayısının yüksekliği ağın öğrenme sürecinde önemli bir etken olsa da, ağın performansını düşürebilmektedir. Bu yüzden bu sayı seçilirken, aktivasyon fonksiyonu, öğrenme yöntemi ve ağın mimarisinin optimizasyonu iyi yapılmalıdır.

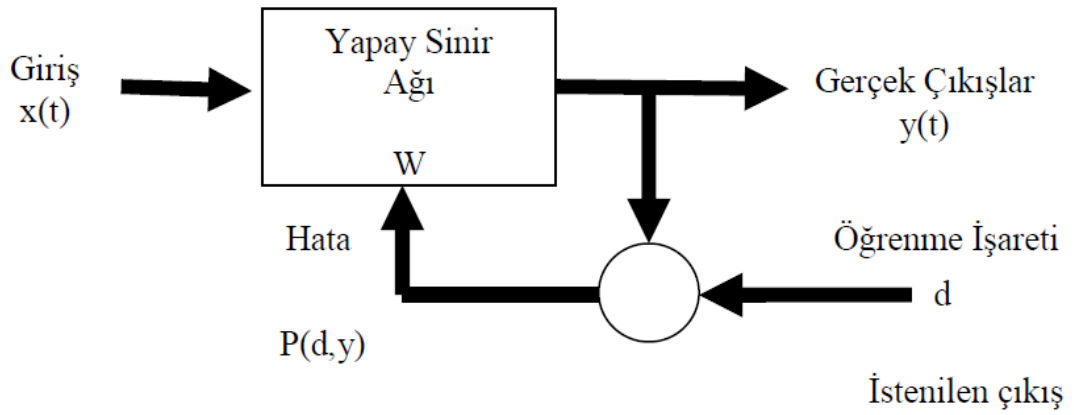
Yapay sinir ağlarında öğrenme algoritmaları, danışmanlı, danışmansız ve takviyeli stratejiler olarak üç gruba ayrılır.

3.8.1. Danışmanlı öğrenme

Danışmanlı öğrenme algoritmasında, ağın eğitimi için ağa örnek girdi değerleri ile birlikte, bu girdilerin hedef çıktı değerleri de verilir.

Danışmanlı öğrenmede, ağın olayı öğrenebilmesi için bir öğretmen yardımcı olmaktadır. Öğretmen ağa belirli girdiler için beklenen çıktı değerlerini de ağa verir. Ağın görevi öğretmenin belirlediği çıktıları haritalamaktır.

Ağ eğitilirken, girdi ve çıktı değerleri ağa gösterilmektedir. Ağ, girdiyi süreçten geçirerek kendi çıktısını üretir ve gerçek çıktı ile karşılaştırır. Öğrenme sayesinde, mevcut hatayı en aza indirmek için bağlantılardaki ağırlıklar yeniden düzenlenir. Bu işlem hata seviyesi kabul edilebilir düzeye inene kadar sürdürülür.



Şekil 3.7. Danışmanlı öğrenme yapısı [3]


Ağın eğitimi için kullanılacak olan eğitim setinin içeriği ağ performansı ve öğrenmenin gerçekleşme süreci açısından çok önemlidir. Üzerinde çalışılan problemin tüm ilişkisel yapısını ve özelliklerini en iyi şekilde temsil eden veri grubu ile sonuca ulaşmak daha hızlı ve güvenilirdir. Bu sebeple eğitim setinin olabildiğince iyi organize edilmesi, modeli temsil edecek tüm özellikleri kapsayacak şekilde değişken yapılarının geniş olması ve eğitime girecek olan veri setlerinin çok olması öncelikle istenilen bir durumdur [3]. Eğer sistemin önemli olan özellikleri ve ilişkileri öğrenmesi gerekiyorsa, o zaman eğitime kümesi, bütün ihtiyaç duyulan bilgileri içermesi lazımdır.

Bu öğrenme şeklinde genellikle hataların hesaplanması için ortalama mutlak hata ve hata kareleri ortalamasının karekökü performans ölçütleri kullanılır. Bu performans ölçütleri yardımıyla ağın ürettiği çıktılar ile hedef çıktılar arasında oluşan hata sinyallerin dikkate alarak kıyaslama yapması sağlanır. Ağın ürettiği çıktılar ile hedef

çıktılar arasındaki hata sinyallerini minimum duruma getirmek amacıyla, işlem elemanları arasındaki bağlantı ağırlıkları düzenlenir [4].

3.8.2. Danışmansız öğrenme

Çıktıların istenen değerleri ağa gösterilmiyorsa, bu tip öğrenme şekli danışmansız öğrenmedir. Danışmansız öğrenmede, girdiler aynı zamanda çıktı görevi görmektedir. Hem çıktı hem de girdi olan veriler arasındaki kural ve ilişkilerin araştırılması ve en optimal olanının bulunması ağın eğitilmesi demektir. Şekil 3.8.'de danışmansız öğrenme yapısı gösterilmektedir.



Şekil 3.8. Danışmansız öğrenme [3]

Danışmansız öğrenmede, danışmanlı öğrenmedeki gibi arzu edilen çıkış değerleri bilinmediğinde girişlerin verdiği cevaplar gözlenerek başarıya ulaşılır. Temelinde, dış müdahale olmaksızın girdilerin ağ tarafından analiz edilmesi ve bu analiz sonucunda bağlantıların oluşturulması sağlanır.

Danışmansız öğrenmede ağ istenen dış verilerle değil, girilen bilgilerle çalışmaktadır. Bu tür öğrenmede gizli sinirler dışarıdan yardım almaksızın kendilerini örgütlemek için bir yol bulur. Bu yaklaşımda, verilen giriş verileri için önceden bilinebilen performansını ölçebilecek ağ için hiçbir çıkış örneği sağlanamaz. Yani ağ yaparak öğrenmektedir.

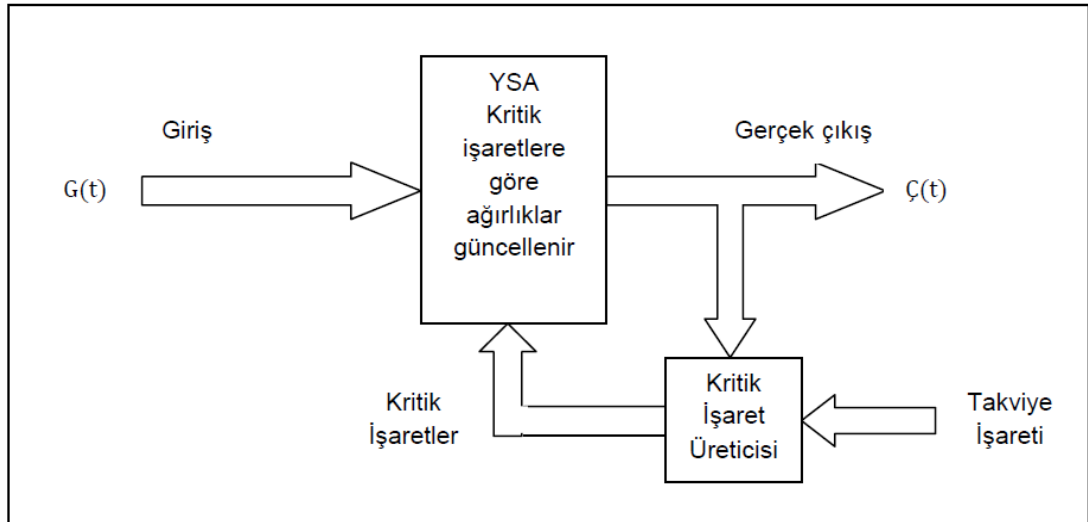
Danışmansız öğrenme metodu, YSA'da sürekli araştırılan ve geliştirilen bir metottur. Bu metot gelecekte bilgisayarların insanların yardımı olmadan öğrenebileceklerini

göstermektedir. Fakat günümüzde sadece sınıflandırma problemlerinde kullanıldığından dolayı pek tercih edilmemektedir.

Ağ, hedef çıktı olmaksızın giriş bilgilerinin özelliklerine göre gruplama yapmak için ağırlık değerlerini ayarlar. Ardından ağ, her küme için örnek bir vektör üretir. Bu tür öğrenmeye örnek olarak, Hebb, Hopfield ve Kohonen öğrenme kuralları verilebilir.

3.8.3. Takviyeli öğrenme

Danışmanlı öğrenmede, ağın davranışının uygun olup olmadığını belirten bir öz yetenek bilgisi gerekmektedir. Bu bilgiye göre ağırlıklar ayarlanır. Gerçek zamanda öğrenme yöntemi olup deneme-yanılma esasına göre sinir ağı eğitilmektedir. Bu yöntem genelde danışmanlı öğrenme yöntemine benzer ama ağa hedef çıktılar yerine ağın çıktılarının ne ölçüde doğru olduğunu belirten bir derece verilir. Performans bilgisi genellikle iki sayıdır ve denetim hareketlerinin başarısını göstermektedir. Boltzman kuralı, takviyeli öğrenmeye örnek verilebilir. Şekil 3.9.'da takviyeli öğrenme gösterilmektedir.



Şekil 3.9. Takviyeli öğrenme yapısı [21]

3.8.4. Karma stratejiler

Yukarıdaki algoritmaların birlikte kullanılarak öğrenmenin gerçekleştiği ağlardır. Kısmen danışmanlı, kısmen danışmansız olarak öğrenme yapmaktadır. Olasılıksal tabanlı ağlar (PBNN) ve radyal tabanlı sinir ağları (RBNN) bunlara örnek gösterilebilir.

3.9. Yapay Sinir Ağlarında Öğrenme Kuralları

Öğrenme kuralları olarak kullanılan çok sayıda algoritma bulunmaktadır. Bu algoritmaların çoğu Hebb kuralına dayanmaktadır. Bu kurallar aşağıdaki gibidir:

1. Hebb Kuralı
2. Hopfield Kuralı
3. Kohonen Kuralı
4. Delta Kuralı

3.9.1. Hebb kuralı

En çok kullanılan yapay sinir ağlarında, bağlantılar arası ağırlık değişimlerinin hesaplamasında Hebb kuralı yaygın olarak kullanılır. Hebb kuralı, sinir ağının bağlantı sayısı değiştirilirse, öğrenebileceğini öngörür.

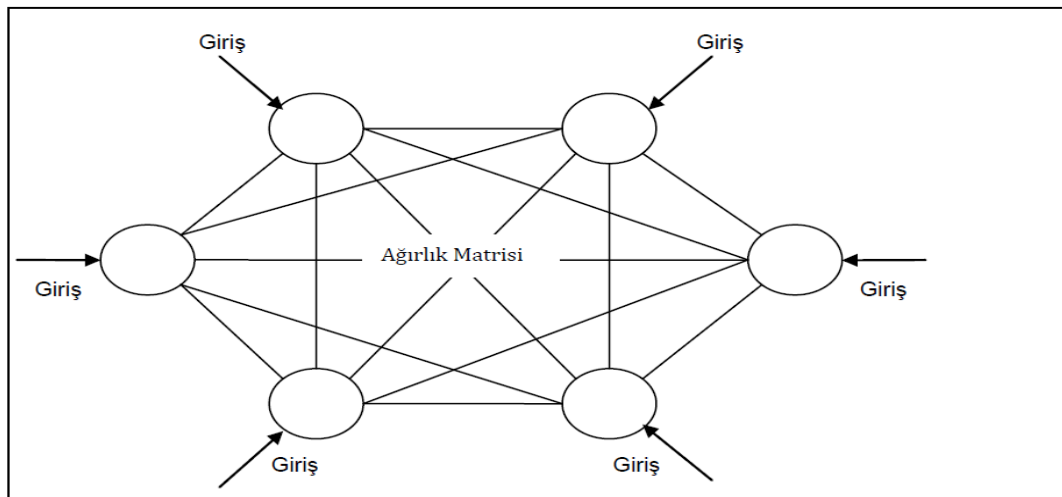
Bu kuralın temelinde, eğer bir nöron diğer bir nörondan girdi aldığı anda bu iki nöron yüksek ilişkide ise yani matematiksel olarak aynı işarete sahipse, nöronlar arasındaki ağırlığın güçlendiği yatmaktadır. Eğer bir ağ içerisinde birbirine bağlı olan iki nöron aynı anda “on” durumunda ise bu anda bu iki nöron arasındaki ağırlık değerlerin artması beklenir ve sinapslarının gerilimiyle öğrenmenin gerçekleştirildiği varsayılmaktadır [4].

3.9.2. Hopfield kuralı

Hebb kuralına benzer bir kuraldır fakat bazı farklılıkları vardır. Bu kurala göre, ağırlıkların güçlendirilmesi işleminde güçlendirme veya zayıflatma için bir büyüklük

tanımlamak gerekmektedir. İstenen çıktı ve girdinin her ikisi de aktif veya pasifse, bağlantı ağırlığı öğrenme oranı kadar artırılır. Ters durumda ise bağlantı ağırlığı öğrenme oranı kadar azaltılır. Hebb kuralından farklı olarak, elemanlarının bağlantılarının ne kadar güçlendirilmesi veya zayıflatılması gerektiğini belirler. Ağırlıkların güçlendirilmesi veya zayıflatılması öğrenme katsayısı ile yapılmaktadır ve öğrenme katsayısı kullanıcı tarafından belirlenen 0-1 arasında sabit pozitif bir değerdir [3].

Hopfield ağı tek katmanlı ve geri dönüşümlü bir ağıdır ve proses elemanlarının tamamı hem girdi hem de çıktı elemanlarıdır. Ağın bağlantı değerleri bir enerji fonksiyonu olarak da saklanmaktadır. Hopfield ağı tekrar beslemeli bir yapıya sahiptir. Şekil 3.10.'da Hopfield ağına ait bir örnek yer almaktadır.



Şekil 3.10. Bir Hopfield ağı örneği [10]

3.9.3. Kohonen kuralı

Kohonen kuralında işlemci elemanlar, ağırlıklarının ayarlanması için yarışmaktadır. Hebb kuralından farklı olarak bir seferde yalnız bir işlemci elemanının, kazanan nöronun bağlantı ağırlıkları değiştirilir. En uygun çıktıya sahip işlemci elemanının kazandığı bu kuralda, kazanan işlemci eleman, kendisine komşu diğer işlemci elemanlarının ağırlıklarının değiştirilmesine de izin vermektedir [9].

Bu kurala göre ağ kendi kendini danışmana ihtiyaç duymadan eğitebilmektedir. Bunun olmasını sağlayan aynı anda paralel bir şekilde en optimal sonucu üretebilmek için düğümlerin yarışmasıdır. Sistem girdi verisini gruplandırmak için hangi özellikleri kullanacağına kendi kendisine karar verir. Ağın bağlantı ağırlıkları için başlangıç değerlerinin verilmesi ve girdi değerlerinin normalize edilmesi lazımdır.

3.9.4. Delta kuralı

Hebb kuralının geliştirilmiş hali de denilen en çok kullanılan kurallardan biri de Delta ağıdır. Beklenen çıktı ile gerçekleşen çıktı arasındaki farkı azaltmak için ağırlıkların sürekli değiştirilmesi gerektiğini belirtir. Ağın hatasının minimizasyonu için, ağırlıklar sürekli güncellenmektedir. Bu kural en küçük kareler kuralını kullanır.

Delta öğrenme kuralında iki çeşit öğrenme algoritması kullanılır:

1. İleri yayımlı öğrenme algoritması
2. Geri yayımlı öğrenme algoritması

Yapılan çalışmalara bakıldığı zaman çoğunlukla kullanılan ileri beslemeli geriye yayımlı yapay sinir ağı modeli kullanılmıştır.

3.10. Geri Yayımlı Algoritması ve Çok Katmanlı Algılayıcılar

Çok katmanlı algılayıcılar (ÇKA); katmanları arasında tam bağlantı bulunan, ileri beslemeli ve danışmanlı olarak eğitilen, çok katmanlı ağlardır. Çok katmanlı geri beslemeli bu ağlarda, bilgi yayılımı geriye doğru olmakta ve bir geri besleme düğüm noktası bulunmamaktadır. Hatalar ağın öğrenme sürecinde geriye doğru yayılarak öğrenilir ve çözüme kavuşturulur [2].

ÇKA ağları birçok uygulamada kullanılmış olan en yaygın öğrenme algoritmasıdır ve özellikle doğrusal olmayan ilişkilerin analizinde etkin sonuçlar verir. Bir ÇKA modelinde; giriş katmanı, gizli katman ve çıkış katmanı olmak üzere en az üç katman bulunmaktadır. Ayrıca problemin özelliklerine göre gizli katman sayısı arttırılabilmektedir. Gizli katman sayısı genellikle bir veya iki olarak kullanılmaktadır.

ÇKA' ların üç ayırt edici özelliği vardır:

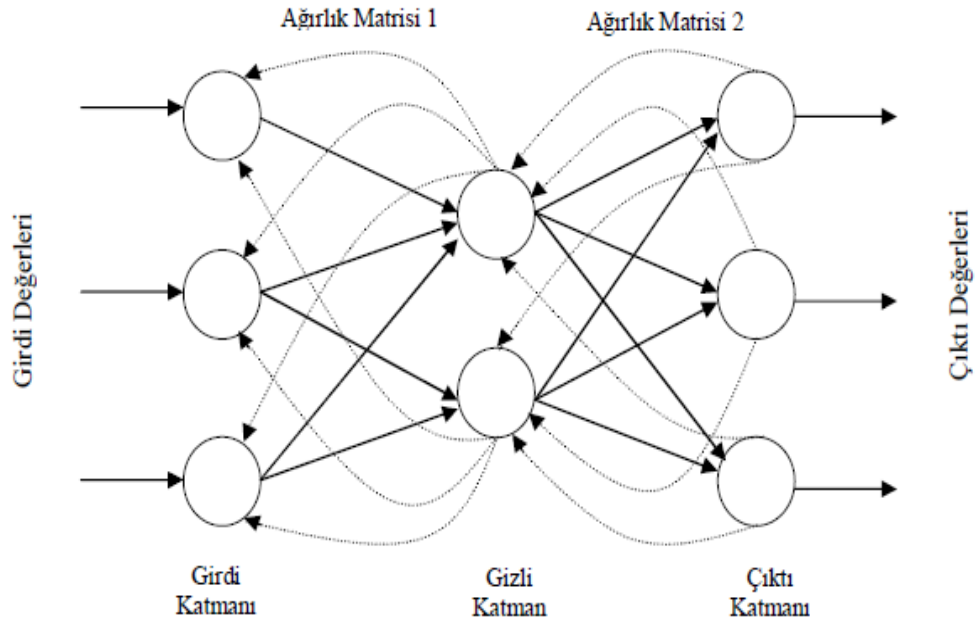
1. Ağdaki her bir nöron doğrusal olmama özelliğine sahiptir. Doğrusal olmama genellikle kullanılan sigmoid fonksiyonu ile sağlanmaktadır.
2. Gizli nöronlardan oluşan bir ya da daha fazla gizli katmana sahiptir. Gizli nöronlar, girdi verisi yapısındaki karmaşık yapıyı öğrenmede ağı başarılı kılar.
3. Ağ bağlantılar sayesinde çok yüksek derecede bilgi işleme becerisi gösterir. Ağın bilgi işleminde değişiklik olabilmesi, bağlantı sayısında ya da ağırlıklarında değişikliği gerektirir.

ÇKA ağları, danışmanlı öğrenme stratejisine göre çalışırlar. Ağın eğitimi sırasında hem girdiler, hem de bu girdilere karşılık üretilmesi gereken çıktılar gösterilir. Ağın görev her girdi için o girdiye karşılık gelen çıktıyı üretmektir. ÇKA ağının öğrenme kuralı ise, en küçük kareler yöntemine dayanan genelleştirilmiş delta kuralıdır. Bu kural iki safhadan oluşur.

1. İleri besleme
2. Geri yayılma

3.10.1. ÇKA' da ileri besleme aşaması

İleri besleme aşamasında, ağın dış dünyadan aldığı girdiler, çıkış katmanına kadar ileri doğru transfer edilirken, geri yayılma aşamasında ise ağın çıktısı ile istenen çıktı arasındaki fark, çıkış katmanından başlayarak geriye doğru giriş katmanına kadar transfer edilir. Bu hata, ağın sinapstik ağırlıklarının değiştirilerek hatanın minimize edilmesi için kullanılır [2].



Şekil 3.11. İleri beslemeli geri yayımlı yapay sinir ağı yapısı [17]

İleri doğru hesaplamada ağın çıktısı hesaplanır. Girdi katmanına gelen girdiler hiçbir işlem görmeden gizli katmana gönderilir.

Gizli katmandaki her bir işlemci eleman, girdi katmanındaki bütün işlemci elemanlardan gelen bilgileri bağlantı ağırlıklarıyla ağırlıklandırarak alır. Önce gizli katmanındaki işlemci elemanlara gelen net girdi Denklem 3.3’de yer almaktadır.

$$s_j^a = \sum_{k=1}^n w_{jk} \cdot y_k^i \quad (3.3)$$

Burada w_{jk} , k. girdi katmanı elemanını, j. gizli katman elemanına bağlayan bağlantının ağırlık değeridir. y_k^i ise girdi katmanındaki k. İşlemci elemanın çıktısını göstermektedir. Aktivasyon fonksiyonu olarak, geriye doğru hesaplamada türevinin alınması gerektiğinden türevi alınabilen bir fonksiyon olan sigmoid fonksiyonu kullanılır. Denklem 3.4.’de yer almaktadır.

$$y_j^a = 1 / (1 + e^{-s_j^a \beta_j^a}) \quad (3.4)$$

Burada β_j , gizli katmanda bulunan j. Elemana bağlanan eşik değer elemanının ağırlığıdır. Bu ağırlık değeri sigmoid fonksiyonunun yönünü belirler. Eğitim esnasında bu değeri ağ kendisi belirler.

Ara ve çıktı katmanlarında işlemci elemanlarının çıktıları da benzer şekilde hesaplanır. Kendisine gelen net girdinin hesaplanması ve sigmoid fonksiyonundan geçirilmesiyle bulunur. En son olarak çıktı değerleri de bulunduğu anda, ağın ileriye doğru hesaplaması tamamlanmış olur.

3.10.2. ÇKA' da geri yayılma aşaması

Ağa sunulan girdi için ağın ürettiği çıktı ile ağın beklenen çıktıları karşılaştırılır. Bunların arasındaki fark hata olarak kabul edilir ve minimum değere indirilmeye çalışılır. Bunun için geriye doğru hesaplamada bu hata ağın ağırlık değerlerine dağıtılarak bir sonraki iterasyonda hatanın azaltılması sağlanır. Çıktı katmanındaki m. işlemci eleman için oluşan hata Denklem 3.5.' de gösterilmektedir.

$$E = d_m - y_m \quad (3.5)$$

E hata değerini, d_m tahmin değerini, y_m ise gerçek değeri göstermektedir. Bu bir tek işlemci eleman için oluşan hatadır. Çıktı katmanı için oluşan toplam hata denklem 3.6'da gösterildiği gibi hesaplanır.

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

Toplam hatayı minimum yapabilmek için, işlemci elemanları hataları önceki katmanlara doğru geri yayarlar. Hatanın iletilmesi, katman katman geriye doğru olmaktadır ve Delta kuralı kullanılarak bağlantı ağırlıkları ayarlanmaktadır. Ağın ağırlıklarını değiştirmek için iki durum vardır:

1. Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi: Gizli katmandaki j . İşlemci elemanı çıktı katmanındaki m . İşlemci elemanına bağlayan bağlantının ağırlıklarındaki değişim miktarı Δw^a olmak üzere herhangi bir t zamanında ağırlığın değişim miktarı aşağıdaki denklem 3.7'deki gibi hesaplanır.

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

Burada λ öğrenme oranını, α momentum katsayısını gösterir. Öğrenme oranı, ağırlıkların bir sonraki düzeltmede hangi oranda değiştirileceğini belirler. Momentum katsayısı, ağırlıkların performansı üzerinde etkisi bulunan diğer bir parametredir. Özellikle yerel çözümlere takılan ağların bir sıçrama ile daha iyi sonuçlar bulmasını sağlamak amacıyla kullanılır. Bu değer küçük olması yerel çözümlerden kurtulmayı, büyük olması ise tek bir çözüme ulaşmayı zorlaştırabilir. Denklem (3.8)'deki δ_m m . işlemci elemanının hatasını gösterir ve Denklem (3.9)'daki gibi hesaplanmaktadır [17].

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

Buradaki $f'(s)$ aktivasyon fonksiyonunun türevidir ve sigmoid fonksiyonu kullanılması haline Denklem (3.9)'da görüldüğü gibi hesaplanmaktadır.

$$\delta_m = y_m * (1 - y_m) * E_m \quad (3.9)$$

Değişim miktarı hesaplandıktan sonra ağırlıkların t . İterasyondaki değerleri Denklem (3.10)'daki gibi hesaplanır.

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

Bundan sonra aynı şekilde eşik değer elemanının da ağırlıklarını değiştirmek gerekir. Bunu yapabilmek için önce değişim miktarı hesaplanır. Çıktı katmanındaki işlemci elemanlarının eşik değer ağırlıkları β^0 ile gösterilirse, bu elemanın çıktısının sabit ve 1 olması nedeni ile değişim miktarı Denklem (3.11)'deki gibi bulunur.

$$\Delta\beta_m^0(t) = \lambda\delta_m + \alpha \Delta\beta_m^0(t-1) \quad (3.11)$$

Eşik değerin t. İterasyondaki ağırlığının yeni değeri ise Denklem (3.12)'deki gibi hesaplanmaktadır.

$$\beta_m^0(t) = \beta_m^0(t-1) + \Delta\beta_m^0(t) \quad (3.12)$$

2. Gizli katmanlar arası veya gizli katman ile girdi katmanı arasındaki ağırlıkların değiştirilmesi: Girdi katman ile gizli katman arasındaki ağırlıkların değiştirilmesinde çıktı katmanındaki tüm işlemci elemanlarının hatası dikkate alınır. Bu ağırlıklardaki değişim Δw ile gösterilirse değişim miktarı Denklem (3.13)'de gösterildiği gibidir.

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

Buradaki δ_j^a hata terimi Denklem (3.14)'deki gibi hesaplanmaktadır.

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

Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılması halinde hata değeri Denklem 3.15'deki gibi bulunur.

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

Değişim miktarı bulunduktan sonra ağırlıkların t. iterasyondaki yeni değerleri Denklem 3.16'deki gibidir.

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

Benzer şekilde eşik değerlerde güncellenir. Eşik değerlerdeki değişim miktarı $\Delta\beta^0$ Denklem (3.17)'deki gibi bulunmaktadır.

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

Ağırlıkların yeni değerleri t. iterasyonda Denklem (3.18)'deki gibi bulunmaktadır.

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

Bir iterasyon önce ileri sonra geriye doğru hesaplamalar yapılarak tamamlanır. Öğrenme tamamlanıncaya kadar bu iterasyonlar devam etmektedir.

3.11. Yapay Sinir Ağı Çalışma Prosedürü

ÇKA ağlarının çalışması için sırasıyla aşağıdaki aşamalar gerçekleştirilir:

1. Örneklerin toplanması: Ağın öğrenmesi istenen durum için, daha önce gerçekleşmiş örneklerin bulunmasıdır.
2. Ağın topolojik yapısının belirlenmesi: Ağın katman sayısı ve bu katmanlarda bulunacak işlem elemanlarının sayısı belirlenir.
3. Öğrenme parametrelerinin belirlenmesi: Öğrenme ve momentum katsayısı ile toplama ve aktivasyon fonksiyonları belirlenir.
4. Ağırlıkların başlangıç değerlerinin atanması: Giriş değerleri ve ara katmanlar için ağırlıklar rastsal olarak (-0.1 , 0.1) arasında belirlenir.
5. Öğrenme setinden örneklerin seçilmesi ve ağa gösterilmesi: Öğrenme setindeki örnekler ağa gösterilir.
6. Öğrenme sırasında ileri hesaplamaların yapılması: Girişe uygulanan vektör için çıktı değerleri ve ağın ürettiği hata değeri belirlenir.
7. Gerçekleşen çıktıyla beklenen çıktının karşılaştırılması: Gerçekleşen çıktı ile beklenen çıktı değerleri karşılaştırılır ve aradaki fark ağın hatası olur.
8. Ağırlıkların değiştirilmesi: Geriye doğru hesap adımları gerçekleştirilerek hata ağın bağlantı ağırlıklarına yayılır.

BÖLÜM 4. TALEP TAHMİNİ UYGULAMASI

Talep tahmini uygulaması, motor yataklarının yıllık satış verilerinden yola çıkılarak yapay sinir ağlarının Matlab (R2013A Sürümü) yazılımı ile gerçekleştirilmiştir. Regresyon ile talep tahmini çalışması Excel programında, zaman serileri ile talep tahmini çalışması ise Minitab programında gerçekleştirilmiştir.


Şahin Motor Yatakları firmasında önceki senelerin satış adetleri üzerinden, gelecek sene için satış tahminleri yapılmaktadır. Yapılan bu tahminler dikkate alınarak yıllık bütçeler hazırlanmakta ve ana üretim planı oluşturulmaktadır. Fakat yapılan tahmin değerleri ile fiili gerçekleşen tahmin değerleri her zaman aynı olmamaktadır. Bu da üretim planlamasından ham malzeme satın almasına kadar her süreci olumsuz etkilemektedir. Geçmiş yılların satış tahminleri üzerine yapay sinir ağları yöntemi veri yapısına uygun YSA modeli belirlenerek gelecek ayların satış adetleri tahmin edilmeye çalışılmıştır. Motor yatağı satışını etkileyen firma dışı faktörlerin belirlenmesi aşamasında Şahin Motor Yatakları firmasının Satış Pazarlama Müdürü, Yurt İçi Satış Sorumlusu ve Planlama Müdürünün görüşlerine başvurulmuştur.

Bu bölümde yapay sinir ağlarının bu problem için uygulama aşamaları anlatılmış ve satış talebini etkileyen faktörler incelenmiştir. Yapay sinir ağları ile yapılan tahmin, çoklu regresyon analizi ve zaman serileri analizleriyle yapılan çalışmalar ile karşılaştırılarak tahminleme performansı test edilmiştir.

4.1. Talep Tahmini Probleminin Tanımlanması

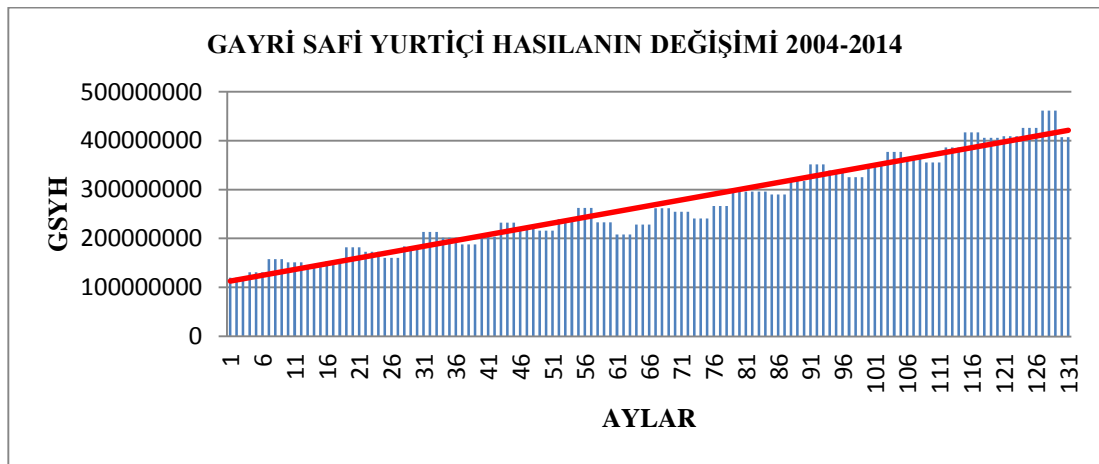
Bu çalışma ile yurt içi oem traktör firmalarına satılan motor yataklarının yıllık satışlarının tahmin edilmesi ve bunu etkileyen faktörlerin belirlenmesi amaçlanmıştır. Bu faktörlerin büyük bir çoğunluğu, traktör satışını da etkileyen faktörler olması pek tabidir. Yurt içi satış talebini etkileyen firma dışı faktörler aşağıdaki gibidir:

1. *Traktör üretim adedi:* Yurt içinde üretilen traktör adeti doğrudan yurt içi satış adetlerini etkilemektedir. Üretim adedi ne kadar çok olursa, motor yatağı satışı da o oranda çok olacaktır. Aşağıdaki Şekil 4.1.'de üretim adedinin 2004- 2014 yılları arasındaki değişimi aylık bazda yer almaktadır.



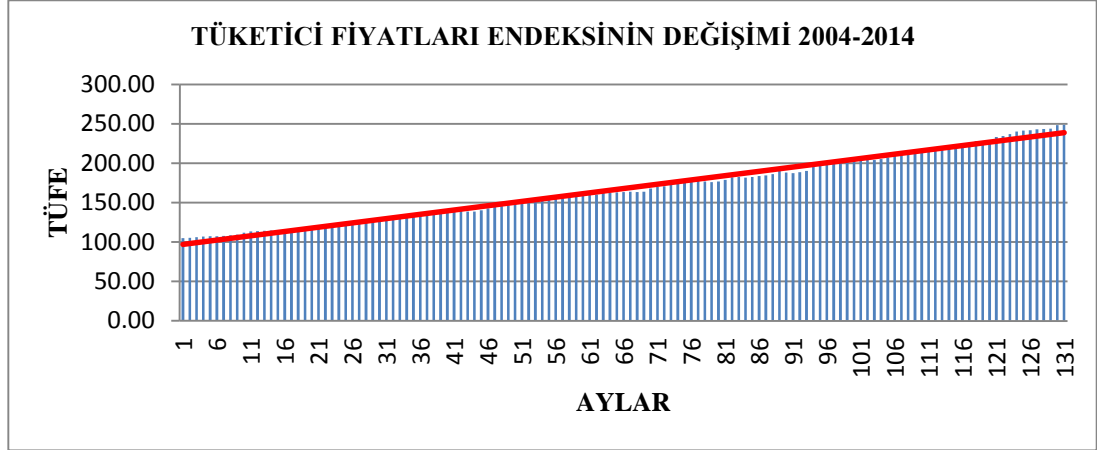
Şekil 4.1. Üretim adedinin değişimi 2004- 2014

2. *Gayri Safi Yurtiçi Hasıla (GSYH):* Bir ülke sınırları içerisinde belli bir zaman içinde üretilen tüm nihai mal ve hizmetlerin para birimi cinsinden değerini ifade eder. Halkın alım gücünü arttırdığı için motor yatağı satışını da arttırması beklenmektedir. Aşağıdaki Şekil 4.2.' de 2004- 2014 yılları arasında GSYH' daki değişim yer almaktadır.




Şekil 4.2. Gayri Safi Yurtiçi Hasılanın Değişimi 2004- 2014

3. *Tüketici Fiyat Endeksi (TÜFE)* : Tüketici tarafından satın alınan mal ve hizmetlerin fiyatlarındaki değişimleri ölçen endekstir. Yılın her ayının belirli günlerinde mal ve hizmet fiyatlarındaki değişim, bu ağırlıklara ölçülerek o ayın tüketici enflasyon rakamına ulaşılmaktadır. Aşağıdaki Şekil 4.3.'de TÜFE' nin 2004-2014 yılları arasındaki değişimi yer almaktadır.




Şekil 4.3. Tüketici Fiyatları Endeksinin Değişimi 2004- 2014

4. *Tarım Ürünleri Üretici Fiyat Endeksi (ÜFE)* : Tarım- ÜFE değeri tarım ürünlerinin, çiftçi tarafından belirlenen fiyatının değişimini ölçen endekstir. Aylık ya da yıllık enflasyon rakamının belirlenmesinde kullanılır. ÜFE' de, fiyatların özellikle üreticilerden derlenmesi esastır ve ürün fiyatları vergiler hariç, yurtiçi peşin satış fiyatlarıdır. Aşağıdaki Şekil 4.4.'de ÜFE' nin 2004- 2014 yılları arasındaki değişimi yer almaktadır.




Şekil 4.4. Üretici Fiyatları Endeksinin Değişimi 2004- 2014

5. *Türkiye’deki traktör ihracatı:* İhracat, bir malın yabancı ülkelere döviz karşılığı yapılan satışlarıdır. İhracatın miktarı traktör üretimini etkileyeceği için, motor yatağı satışını da etkilemektedir. Aşağıdaki Şekil 4.5.’de ihracat adetinin 2004- 2014 yılları arasındaki aylık değişimi yer almaktadır.




Şekil 4.5. İhracat adetinin değişimi 2004- 2014

6. *İMKB gecelik faiz oranı:* Taahhüt kredilerine uygulanan faiz oranı arttıkça traktör satış adetlerinde düşmeler görülmektedir. Bu da doğrudan motor yatağı satışlarını etkilemektedir. Aşağıdaki Şekil 4.6.’da İMKB gecelik faiz oranının 2004- 2014 yılları arasındaki aylık değişimi yer almaktadır.




Şekil 4.6. İMKB gecelik faiz oranının değişimi 2004- 2014

7. *Dolar kuru:* Bir Amerikan dolarının, Türk Lirası üzerinden değerini belirtir. Yurtiçi oem traktör firmalarına dolar üzerinden satış yapılmaktadır. Bu yüzden dolar kurunun değişimi, motor yatağı satışını etkilemektedir. Aşağıdaki Şekil 4.7.'de dolar kurunun 2004- 2014 yılları arasındaki aylık değişimi yer almaktadır.



Şekil 4.7. Dolar kurunun değişimi 2004- 2014

8. *Türkiye'deki Traktör Araç Parkı:* Türkiye' de trafiğe kayıtlı olan traktör miktarıdır. Trafiğe kayıtlı araç miktarı arttıkça ve araçlar eskidikçe motor yenileme hızı artmaktadır. Bu da motor yatağı satışını etkilemektedir. Aşağıdaki Şekil 4.8.'de 2004- 2014 yılları arasındaki Türkiye' deki traktör araç parkı değişimini aylar bazında göstermektedir.



Şekil 4.8. Araç parkı sayısının değişimi 2004- 2014

Bu faktörlere ek olarak veri iki faktörde yurtiçi oem traktör motor yatağı satış talebini etkilemektedir. Bunlardan ilki müşteriye fiyat iskontosunun yapıldığı kampanyalı satış dönemleridir. Bu dönemlerde fiyatlar düşük olduğundan satışlar artmaktadır. Diğer önemli neden, yaz aylarında müşteri firmalarının yapmış oldukları duruşlardır. Duruş dönemlerinden önceki ve sonraki aylarda satış adetlerinde artış görülmektedir. Bu iki faktörün geçmiş dönemlere ait veri toplanma olanağı olmadığı için uygulamaya alınamamıştır.

Bu çalışmada kullanılan verilerin çoğu Türkiye İstatistik Kurumu (TUIK), Merkez Bankası, Otomotiv Sanayi Derneği (OSD) verilerinden derlenmiştir. Girdi ve çıktı verilerini gösteren tablo Ek1’de sunulmuştur.

4.2. Yapay Sinir Ağı Mimarisi

Talep tahmininde en çok kullanılan yöntem, geri yayılım algoritmasıdır. Bu nedenle yapılan çalışmada çok katmanlı ileri beslemeli geri yayılım algoritması kullanılmıştır. Ocak 2004 –Aralık 2014 yılları arasındaki 131 adet veri kullanılmaktadır. 2004- 2012 yılları arasındaki 95 adet veri ağın eğitimi için, Ocak 2012- Aralık 2014 yılları arasındaki 36 adet aylık veriler ise ağın performansının test edilmesi için kullanılmaktadır. Normalizasyon tekniği olarak en çok kullanılan D_Min_Max yöntemi kullanılarak, tüm veriler [0.1, 0.9] arasında normalize edilmiş ve programa aktarılmıştır. Çalışma kapsamında oluşturulan tüm modeller giriş katmanı, çıktı katmanı ve gizli katmandan oluşmuştur. Girdi katmanı sekiz hücreden, çıktı katmanı ise bir hücreden oluşmaktadır. Gizli katmanda ise farklı sayılarda hücre bulunabilir, bunun için ileriki kısımlarda en uygun hücre sayısı bulmak için denemeler yapılmıştır. Yapay sinir ağı modellenmesinde gizli hücre sayısını elde etmek için “geometrik piramit kuralı” olarak adlandırılan bir yöntem kullanılır. Bu kurala göre, girdilerden çıktılara doğru hücre sayısının azalması gerektiği varsayımına dayanır. Gizli hücre sayısı piramit kuralı gereği, girdi hücre sayısının iki katı olan on altıyı geçemez. Ayrıca bu sayı, girdi hücre sayısı ile çıktı hücre sayısının çarpımının karekökünden de az olamaz. 500 farklı deneme yapılmıştır.

Eđitim verileri ađa sunularak ađın renmesi gerekleřtirilmiř ve bu beř yz model ierisinde test verileri iin, hata kareleri ortalaması (MSE), ortalama mutlak yzde hata (MAPE) ve ortalama mutlak hata (MAE) istatistiksel hata deđerlerinden en kyk hata deđerini veren YSA modeli seilmiřtir.

4.3. Yapay Sinir Ađı Matlab Uygulamaları

Yapılan alıřmada ncelikle evrim sayısı sabit tutularak momentum ve renme katsayılarının en uygun deđerleri bulunmaya alıřılmıřtır. Bunun iin evrim sayısı 1000’ de sabit tutularak momentum ve renme katsayıları deđiřtirilmiř, en uygun deđerler belirlenmiřtir. Hcre sayısı, momentum katsayısı ve renme katsayısındaki deđiřimler tahmin sonularını etkilemektedir. Bu yzden ok fazla deneme yapılıp sonuları karřılařtırılmıřtır.

ncelikle renme katsayısını bulabilmek iin 0.1-0.9 arasındaki deđerler denenmiřtir. Daha sonra belirlenen optimal renme katsayısını dikkate alarak momentum katsayısı 0.1-0.9 deđerleri arasında denemeler yapılmıř, belirlenen optimal aralıklarda yođunlařarak elde edilen sonular bu alıřmada anlatılmıřtır. renme katsayısı yapılan denemeler sonucunda 0.9 olarak bulunmuřtur.

renme katsayısı 0.9 bulunduktan sonra momentum katsayısının bulunması iin tm parametreler sabit tutularak 0.1-0.9 aralıđında denemeler yapılmıřtır. Denemeler sonucunda renme katsayısı 0.7 olarak belirlenmiřtir. Daha sonra bu katsayılar dikkate alınarak, evrim sresinin optimal deđerleri bulunmaya alıřılmıřtır. 250-5000 arasındaki deđerler denenerek, en uygun evrim sresi 2250 olarak belirlenmiřtir.

Momentum katsayısı, renme katsayısı ve evrim sayılarının optimal deđerleri belirlendikten sonra gizli hcre sayısının en uygun deđerinin belirlenmesi gerekmektedir. Gizli hcre sayısı kural olarak girdi hcre sayısının 2 katını geemez. Bu yzden denemeler 3-16 arasında yapılmıřtır. En uygun gizli hcre sayısı 3 olarak bulunmuřtur.

Gizli hücrelerdeki nöron sayısının en optimal değeri 13 olarak belirlenmiştir. Tek katmanlı ve çift katmanlı ağ yapısı için denemeler de yapılmış ve bu uygulama için tek katmanlı yapının uygun olduğu ortaya çıkmıştır. Tüm parametreler belirlendikten sonra ağ eğitilmiştir. Test verileri ağa uygulanarak, doğruluğu test edilmiştir.

Aktivasyon fonksiyonu olarak logaritmik sigmoid fonksiyonu en optimal sonuçları verdiği için denemeler bu fonksiyon ile gerçekleştirilmiştir. Hiperbolik tanjant fonksiyonu ile de denemeler yapıldığı halde çok iyi sonuçlar bulunmamıştır.

4.3.1. Öğrenme katsayısının belirlenmesi

Öğrenme katsayısının belirlenmesi ağın öğrenme performansı açısından oldukça önem taşımaktadır. Bu katsayı ağırlıkların değişim miktarını belirlemede, büyük ve küçük değerlerin seçilmesi ağın öğrenme hızını etkilemektedir. Küçük değerlerin seçilmesi, ağın öğrenme zamanını arttırır. Büyük değerlerin seçilmesi, ağın yerel çözümler arasında ağın dolaşmasına sebep olmaktadır.

Yapılan denemeler sonucunda öğrenme katsayısının en uygun değeri 0.2 - 0.4 arasında olduğu bilinmektedir. Momentum katsayısını 0.6 için ve çevrim sayısını 1000 alarak öğrenme katsayıları değiştirilerek en uygun olanı bulunmaya çalışılmıştır. Bu çalışma için en uygun değerler 0.6 ve 0.9 olduğu görülmüştür. Yapılan denemeler sonucunda en iyi sonuçları veren aktivasyon fonksiyonunun logsig olduğuna karar verilmiştir. Aşağıdaki Tablo 4.1.'de bu denemeler yer almaktadır.

Tablo 4.1. Öğrenme katsayısının belirlenmesi

Öğrenme Katsayısının Belirlenmesi	
Ağ Tipi :	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)
Eğitim Fonksiyonu:	Traingdm (Momentum Terimli Geri Yayılım Algoritması)
Öğrenme Fonksiyonu:	Learngdm
Aktivasyon Fonksiyonu:	Tansig- Logsig
Nöron Sayısı :	10
Gizli Hücre Sayısı :	3
Gizli Katman Sayısı:	1
Momentum Katsayısı:	0.6
Çevrim Sayısı:	1000

Tablo 4.1. Öğrenme katsayısının belirlenmesi (Devamı)

Deneme No	Öğrenme Katsayısı	Tahmin Değeri	MSE	MAD	MAPE %	Aktivasyon Fonksiyonu
1	0,1	11,685	0,0194	0,1165	50,96	Logsig
2	0,2	10,209	0,0109	0,0786	37,35	Logsig
3	0,3	10,096	0,0065	0,0646	30,10	Logsig
4	0,4	11,189	0,0108	0,0757	34,88	Logsig
5	0,5	16,253	0,0517	0,2144	97,38	Logsig
6	0,6	7,063	0,0047	0,0573	22,83	Logsig
8	0,8	10,866	0,0081	0,0710	31,22	Logsig
9	0,9	6,746	0,0052	0,0570	22,17	Logsig
10	0,1	14,310	0,0381	0,1628	74,18	Tansig
11	0,2	9,660	0,0228	0,1343	60,57	Tansig
12	0,3	11,906	0,0238	0,1074	47,66	Tansig
13	0,4	12,400	0,0181	0,1162	53,61	Tansig
14	0,5	9,632	0,0066	0,0608	25,72	Tansig
15	0,6	9,918	0,0055	0,0524	25,64	Tansig
16	0,7	10,504	0,0148	0,0893	39,88	Tansig
17	0,8	8,472	0,0144	0,0895	41,34	Tansig
18	0,9	11,855	0,0250	0,1227	54,30	Tansig

4.3.2. Momentum katsayısının belirlenmesi

Momentum katsayısı bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesidir. Bu değerın küçük olması yerel çözümlerden kurtulmayı zorlaştırırken, çok büyük olması tek bir çözüme ulaşmakta sorun çıkartabilir [4]. Momentum katsayısı öğrenme performansını etkiler. Momentum katsayısı, yerel çözümlere takılan ağların, sıçrama ile daha iyi sonuçlar bulmasına yardımcı olur. Çok büyük değerler sonucu ulaşmada sorunlar yaşatabilir. Bu değerın 0.6-0.8 arasında en optimal olduğu düşünülmektedir.

Öğrenme katsayısı 0.6 ve 0.9 alınarak 1000 çevrim için momentum katsayıları değiştirilerek en uygun momentum katsayısı bulunmaya çalışılmıştır. Aktivasyon fonksiyonu olarak logsig denenmiştir. Aşağıdaki tabloda 2012- Aralık 2014 verileri için gerçekleşen değerler ile momentum katsayısının farklı değerlerine göre tahmin

edilen değerler kıyaslanmıştır. Buna göre en uygun momentum katsayısının sırasıyla 0.7-0.4 ve 0.8 olduğuna karar verilmiştir. Tablo 4.2.'de bu denemeler yer almaktadır.

Tablo 4.2.'de görüleceği üzere en iyi çözümü momentum katsayısı 0.7, öğrenme katsayısı 0.9 kombinasyon vermiştir. Bunun dışında, momentum katsayısının 4 olduğu denemede MSE değeri olarak 0.031 olarak bulunmuştur.

Tablo 4.2. Momentum katsayısının belirlenmesi

Momentum Katsayısının Belirlenmesi							
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)						
Eğitim Fonksiyonu	Traingdm (Momentum Terimli Geri Yayılım Algoritması)						
Öğrenme Fonksiyonu	Learnadm						
Aktivasyon Fonksiyonu	Logsig						
Nöron Sayısı	10						
Gizli Hücre Sayısı	3						
Gizli Katman Sayısı	1						
Öğrenme Katsayısı	0.6 – 0.9						
Çevrim Sayısı	1000						
Deneme No	Momentum Katsayısı	Öğrenme Katsayısı	Tahmin	MSE	MAD	MAPE %	
19	0,1	0,6	15,762	0,0448	0,1997	91,73	
20	0,2	0,6	15,579	0,0534	0,1980	88,08	
21	0,3	0,6	9,392	0,0053	0,0503	21,82	
22	0,4	0,6	8,624	0,0031	0,0425	18,16	
23	0,5	0,6	12,184	0,0145	0,1100	51,56	
6	0,6	0,6	7,063	0,0047	0,0573	22,83	
24	0,7	0,6	8,067	0,0066	0,0643	27,45	
25	0,8	0,6	11,624	0,0172	0,1066	45,97	
26	0,9	0,6	10,758	0,0250	0,1120	47,80	
27	0,1	0,9	6,694	0,0079	0,0734	29,75	
28	0,2	0,9	12,832	0,0188	0,1183	54,68	
29	0,3	0,9	15,174	0,0511	0,1883	83,99	
30	0,4	0,9	5,579	0,0099	0,0852	33,51	
31	0,5	0,9	10,160	0,0178	0,1004	44,21	
32	0,6	0,9	6,746	0,0052	0,0570	22,17	
33	0,7	0,9	8,783	0,0027	0,0447	19,65	
34	0,8	0,9	9,552	0,0041	0,0509	23,74	
35	0,9	0,9	13,374	0,0242	0,1384	66,01	

4.3.3. Çevrim sayısının belirlenmesi

Belirli bir denemeden sonra ağın öğrenmesinin durduğu düşünülür. Bu noktadan sonra ağ daha fazla öğrenemez ve daha iyi bir sonuç bulunamaz. Momentum katsayısı 0.4 ve 0.7 öğrenme katsayısı 0.6 ve 0.9 alınarak en uygun çevrim sayısı bulma denemeleri yapılmıştır. Aşağıdaki Tablo 4.3.'de bu denemeler yer almaktadır.

250 - 5000 arasında çevrim sayıları denenmiş ve en uygun çevrim sayısının 2250 olduğu belirlenmiştir.(Deneme 59) Tablo 4.3.'de görüleceği üzere diğer en iyi değeri veren diğer çevrim sayısı ise 1000'dir. (Deneme 54)

Tablo 4.3. Çevrim sayısının belirlenmesi

Çevrim Sayısının Belirlenmesi							
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)						
Eğitim Fonksiyonu	Traingdm (Momentum Terimli Geri Yayılım Algoritması)						
Öğrenme Fonksiyonu	Learngdm						
Aktivasyon Fonksiyonu	Logsig						
Nöron Sayısı	10						
Gizli Hücre Sayısı	3						
Gizli Katman Sayısı	1						
Öğrenme Katsayısı	0.6-0.9						
Momentum Katsayısı	0.4-0.7						
Deneme No	Momentum Katsayısı	Öğrenme Katsayısı	Çevrim Sayısı	Tahmin Değeri	MSE	MAD	MAPE %
36	0,4	0,6	250	10,358	0,0115	0,0768	37,84
37	0,4	0,6	500	5,348	0,0136	0,1036	42,01
38	0,4	0,6	750	9,048	0,0073	0,0595	27,69
39	0,4	0,6	1000	8,624	0,0031	0,0425	18,16
40	0,4	0,6	1250	7,003	0,0095	0,0834	34,46
41	0,4	0,6	1500	6,031	0,0071	0,0725	28,69
42	0,4	0,6	1750	17,758	0,0709	0,2561	112,52
43	0,4	0,6	2000	7,511	0,0072	0,0712	29,58
44	0,4	0,6	2250	13,764	0,0368	0,1543	67,91
45	0,4	0,6	2500	9,020	0,0043	0,0500	22,66
46	0,4	0,6	3000	16,827	0,0606	0,2293	102,66
47	0,4	0,6	3500	7,927	0,0033	0,0482	20,11
48	0,4	0,6	4000	12,492	0,0192	0,1202	57,64
49	0,4	0,6	4500	24,008	0,2147	0,4288	184,04
50	0,4	0,6	5000	10,531	0,0172	0,0922	40,24

Tablo 4.3. Çevrim sayısının belirlenmesi (Devamı)

Deneme No	Momentum Katsayısı	Öğrenme Katsayısı	Çevrim Sayısı	Tahmin Değeri	MSE	MAD	MAPE %
51	0,7	0,9	250	5,365	0,0195	0,1245	52,14
52	0,7	0,9	500	10,149	0,0134	0,0737	32,77
53	0,7	0,9	750	14,433	0,0315	0,1628	76,16
54	0,7	0,9	1000	8,783	0,0027	0,0447	19,65
55	0,7	0,9	1250	4,265	0,0186	0,1252	50,04
56	0,7	0,9	1500	7,025	0,0060	0,0572	22,80
57	0,7	0,9	1750	7,637	0,0048	0,0574	23,99
58	0,7	0,9	2000	6,989	0,0078	0,0697	28,61
59	0,7	0,9	2250	8,445	0,0026	0,0412	17,73
60	0,7	0,9	2500	10,680	0,0142	0,0866	40,97
61	0,7	0,9	3000	4,249	0,0171	0,1201	48,29
62	0,7	0,9	3500	6,571	0,0061	0,0635	24,95
63	0,7	0,9	4000	8,779	0,0031	0,0425	18,97
64	0,7	0,9	4500	24,666	0,2086	0,4471	195,19
65	0,7	0,9	5000	6,420	0,0057	0,0610	23,69

4.3.4. Nöron sayısının belirlenmesi

Ağın yapısal özelliklerinden biri de her katmandaki nöron sayısıdır. Bir katmanda kullanılacak nöron sayısının olabildiğince az olması makbuldür. Nöron sayısının az olması YSA' nın genelleme yeteneğini arttırmaktadır. Gereğinden fazla olması ağın verileri ezberlemesine yol açabilmektedir. Zaman serisi tahmin problemlerinde nöron sayısı, gecikme sayısı ile ilişkilidir ve bu sayıyı belirleyebilmek için belli bir yol yoktur.

Momentum katsayısı, öğrenme katsayısı ve çevrim sayısı belirlendikten sonra en uygun nöron sayısının belirlenmesi çalışmaları yapılmıştır. 1-20 arasında yapılan denemelerde en uygun nöron sayısının 13 olduğu bulunmuştur.(Deneme 78) Diğer en iyi sonucu veren nöron sayısı 10'dur. (Deneme 75, MSE değeri= 0.026'dır.) Aşağıdaki Tablo 4.4.'de bu denemeler yer almaktadır.

Tablo 4.4. Nöron sayısının belirlenmesi

Nöron Sayısının Belirlenmesi							
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)						
Eğitim Fonksiyonu	Traingdm (Momentum Terimli Geri Yayılım Algoritması)						
Öğrenme Fonksiyonu	Learnqdm						
Aktivasyon Fonksiyonu	Logsig						
Nöron Sayısı	10						
Gizli Hücre Sayısı	3						
Gizli Katman Sayısı	1						
Öğrenme Katsayısı	0.9						
Momentum Katsayısı	0.7						
Çevrim Sayısı	2250						
Deneme No	Momentum Katsayısı	Öğrenme Katsayısı	Nöron Sayısı	Tahmin Değeri	MSE	MAD	MAPE %
66	0,7	0,9	1	8,591	0,0054	0,0544	24,34
67	0,7	0,9	2	8,026	0,0036	0,0527	22,21
68	0,7	0,9	3	5,376	0,0136	0,1038	41,58
69	0,7	0,9	4	14,641	0,0400	0,1688	75,82
70	0,7	0,9	5	4,216	0,0175	0,1210	48,44
71	0,7	0,9	6	9,261	0,0063	0,0600	26,77
72	0,7	0,9	7	18,669	0,1131	0,2833	130,29
73	0,7	0,9	8	12,638	0,0170	0,1160	52,48
74	0,7	0,9	9	7,539	0,0051	0,0618	25,33
75	0,7	0,9	10	8,445	0,0026	0,0412	17,73
76	0,7	0,9	11	12,185	0,0158	0,1118	53,22
77	0,7	0,9	12	10,110	0,0067	0,0692	30,57
78	0,7	0,9	13	9,009	0,0024	0,0412	18,37
79	0,7	0,9	14	10,021	0,0044	0,0549	25,96
80	0,7	0,9	15	5,983	0,0094	0,0789	30,80
81	0,7	0,9	16	8,251	0,0119	0,0783	34,29
81	0,7	0,9	17	10,858	0,0100	0,0785	37,42
83	0,7	0,9	18	6,139	0,0093	0,0826	32,84
84	0,7	0,9	19	9,272	0,0052	0,0574	26,68
85	0,7	0,9	20	8,427	0,0051	0,0544	22,06

4.3.5. Gizli hücre sayısının belirlenmesi

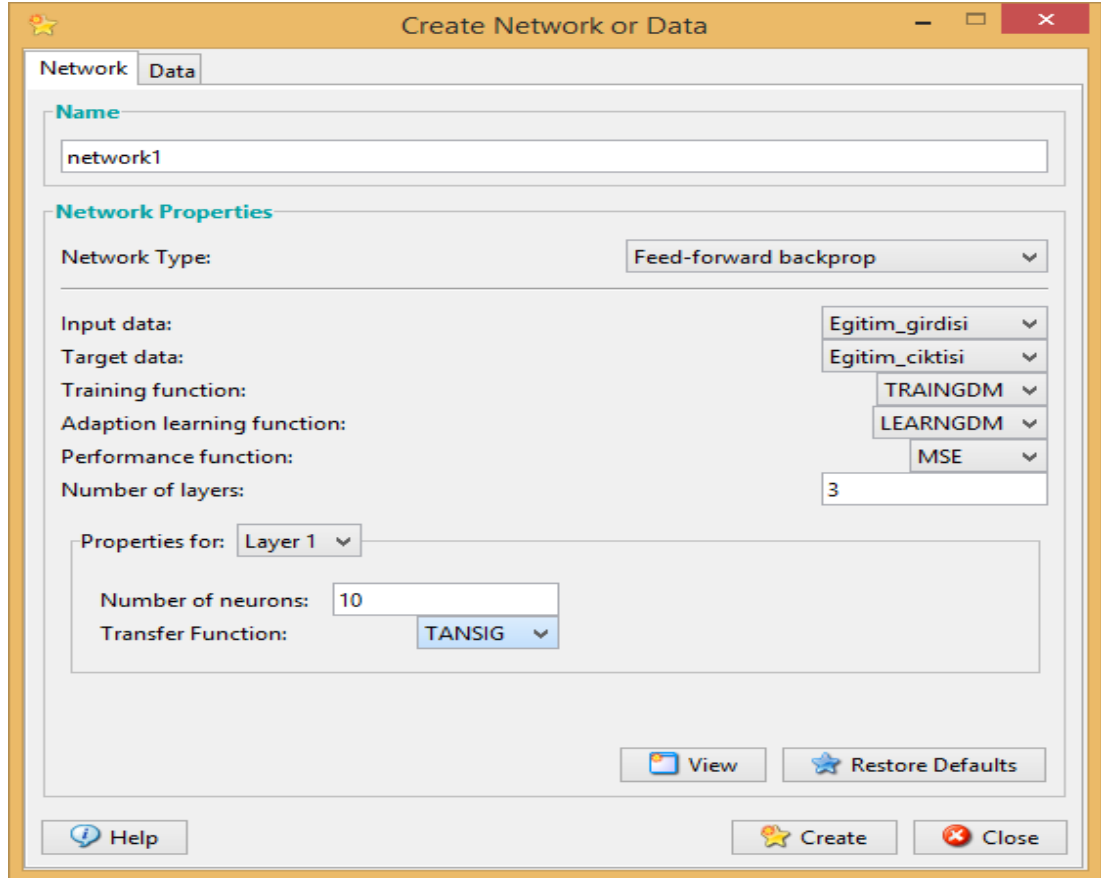
Momentum katsayısı 0.7, öğrenme katsayısı 0.9, çevrim sayısı 2250 alınarak ve nöron sayısı 13 olarak bulunduktan sonra gizli hücre sayısının hesaplanmasına sıra geldi. Gizli hücre sayısı 3' ten giriş hücre sayısının iki katı olan 16' a kadar denemeler yapılmıştır. En iyi hücre sayısının 3 olduğu belirlenmiştir. Aşağıdaki Tablo 4.5.'de bu denemeler yer almaktadır.

Tablo 4.5. Gizli hücre sayısının belirlenmesi

Gizli Hücre Sayısının Belirlenmesi						
Ağ Tipi	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)					
Eğitim Fonksiyonu	Traingdm (Momentum Terimli Geri Yayılım Algoritması)					
Öğrenme Fonksiyonu	Learngdm					
Aktivasyon Fonksiyonu	Logsig					
Nöron Sayısı	13					
Gizli Katman Sayısı	1					
Öğrenme Katsayısı	0.9					
Momentum Katsayısı	0.7					
Çevrim Sayısı	2250					
Deneme	Gizli Hücre Sayısı	Tahmin Değeri	MSE	MAD	MAPE %	
	84	3	9,009	0,0024	0,0412	18,37
	92	4	5,820	0,0144	0,1012	40,97
	93	5	12,340	0,0179	0,1103	49,78
	94	6	6,258	0,0082	0,0804	33,34
	95	7	12,588	0,0235	0,1229	54,20
	96	8	13,081	0,0360	0,1444	68,12
	97	9	10,964	0,0168	0,0941	43,30
	98	10	4,874	0,0157	0,1111	44,05
	99	11	9,931	0,0070	0,0653	29,42
	100	12	13,637	0,0502	0,1624	67,13
	101	13	13,588	0,0268	0,1440	67,70
	102	14	6,376	0,0076	0,0714	27,75
	103	15	10,226	0,0060	0,0674	30,99
	104	16	4,707	0,0167	0,1150	45,56

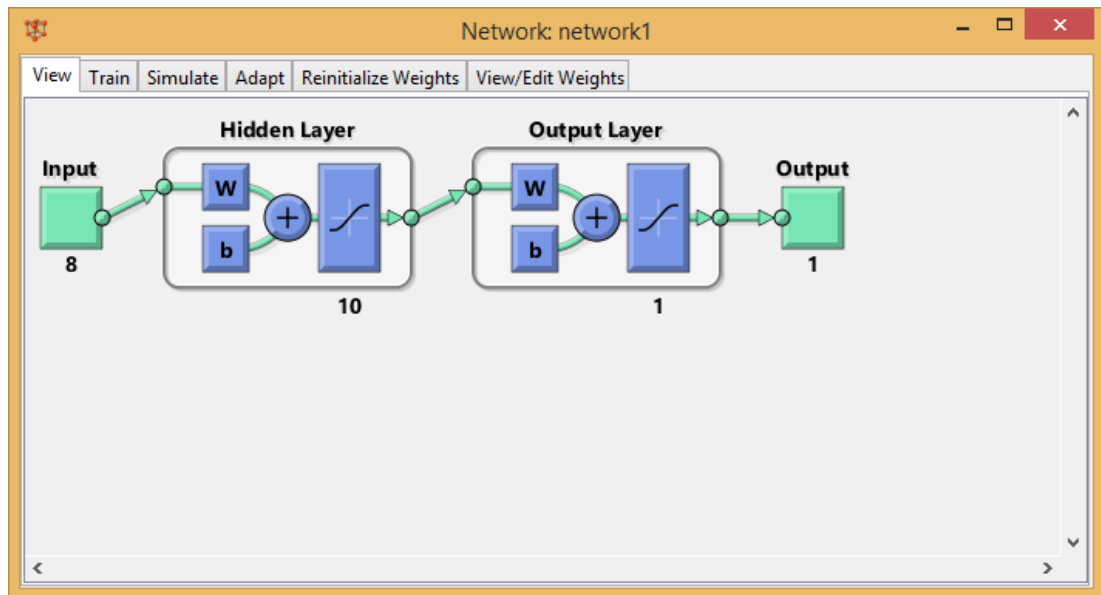
4.4. Yapay Sinir Ağının Eğitilmesi

Ağın eğitilmesi için Matlab R2013A programının Neural Network uygulaması kullanılmıştır. Yeni bir ağ yaratma penceresi Şekil 4.9.'da gösterilmektedir. Öncelikle bu pencerenin "Data" kısmında normalize edilmiş olan eğitim girdi ve çıktı seti girilir. Daha sonra gene aynı yerden test girdi verisinin normalize edilmiş haliyle girişi yapılır. "Network" kısmında oluşturmak istediğimiz ağ ile ilgili ağ tipi, eğitim girdi- çıktı verisi, eğitim ve öğrenme algoritmaları, performans fonksiyonu, katman sayısı, gizli hücre sayısı, nöron sayısı ve aktivasyon fonksiyonu girişleri yapılır ya da açılan butonlardan seçim yapılır. İlgili yerler doldurulduktan sonra "Create" butonuna basılarak ağ yaratma işlemi gerçekleştirilir.



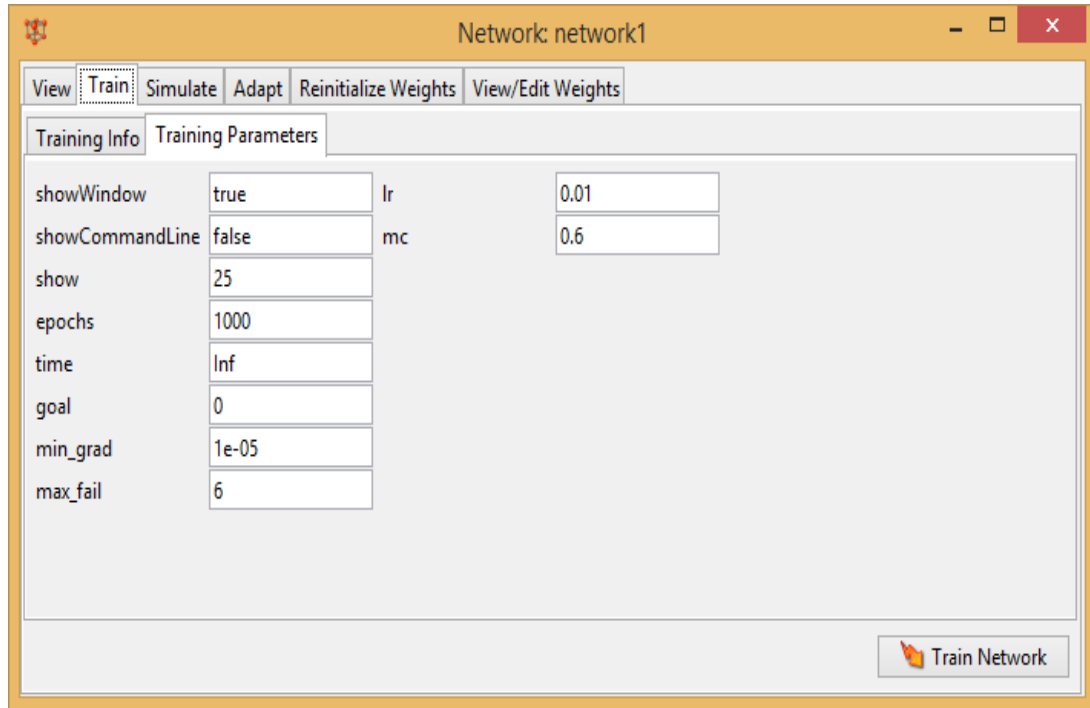
Şekil 4.9. Matlab'ta yeni ağ yaratma penceresi

Şekil 4.10.' da oluşturulan yapay sinir ağı modelinin görüntüsü yer almaktadır.



Şekil 4.10. Yapay Sinir Ağı Gösterimi


Şekil 4.10.'daki matlab penceresinin “Train” sekmesinde ağın eğitim işlemi gerçekleştirilir. Şekil 4.11.'de Train sekmesi görünmektedir. Burada momentum katsayısı, öğrenme katsayısı ve çevrim sayısı gibi öğrenme performansını etkileyen parametreler seçilir. Daha sonra “Train Network” butonuna basılarak ağ eğitilir.



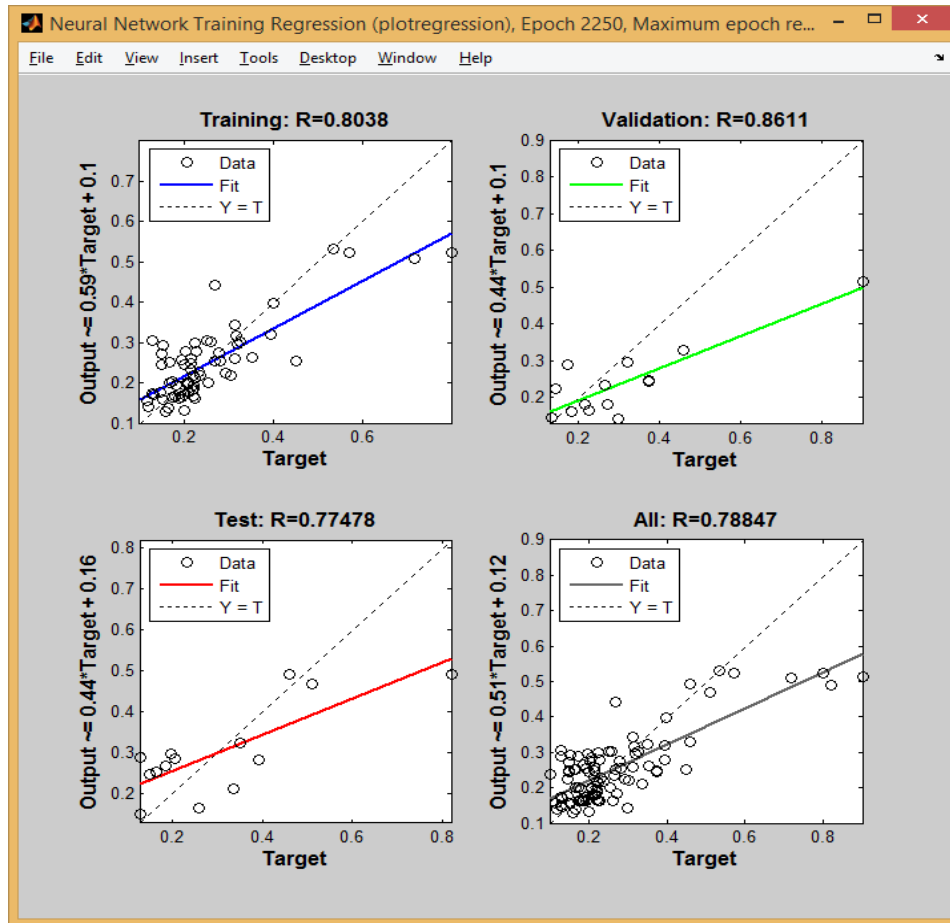
Şekil 4.11. Matlab'ta YSA eğitim ekranı

Eğitim sonucunda her iterasyondaki eğitim, doğrulama ve test kümelerine ilişkin hata değerlerinin ne şekilde değiştiğini gösteren grafik Şekil 4.12.'de yer almaktadır. Grafikte görüldüğü üzere ağın eğitimi 2250 iterasyonda optimum sonuca ulaşmıştır.

Matlabta öğrenmeden sonra elde edilene regresyon grafiği Şekil 4.13.'de gösterilmektedir. Bu grafiğe göre en düşük değer 0.77478 olan test kümesine aittir. Buradan da anlaşılacağı üzere öğrenme işlemi büyük başarıyla gerçekleştirilmiştir. Bağımsız değişken olarak belirlediğimiz faktörler en az 0.77 oranında satış talebini etkilemektedir.



Şekil 4.12. Eğitim, doğrulama ve test kümelerine ilişkin hata performansları



Şekil 4.13. Matlab'ta öğrenme, doğrulama ve test kümelerine ilişkin regresyon grafiği

Tablo 4.6.'da eğitim sonucunda belirlemiş olduğumuz minimum hata değerini veren YSA parametreleri yer almaktadır. Bu parametreleri kullanarak ağı test etme işlemi yapılmaktadır.

Tablo 4.6. YSA Parametreleri

PARAMETRELER	
Ağ Tipi:	İleri Beslemeli Geri Yayılım Algoritması (Feed Forward Backprop)
Eğitim Fonksiyonu:	Traingdm (Momentum Terimli Geri Yayılım Algoritması)
Öğrenme Fonksiyonu:	Learngdm
Aktivasyon Fonksiyonu:	Logsig (Sigmoid)
Gizli Katman Sayısı:	1
Momentum Katsayısı:	0.7
Öğrenme Katsayısı:	0.9
Çevrim Sayısı:	2250
Gizli Hücre Sayısı:	3
Nöron Sayısı:	13

Yapay sinir ağı eğitimini tamamlamasıyla ağ öğrenme işlemi tamamlar. Ağın öğrenmesindeki amaç, ağın giriş nöronları ile çıkış nöronunun ağırlık değerlerinin belirlenmesidir [12]. Matlab programı ile ara katmandaki on üç adet nöron ve çıkış katmanında bulunan bir adet nöronun eşik değeri de belirlenmiştir. Tablo 4.7. ve 4.9.'da ağırlık değerleri, Tablo 4.8. ve 4.10.'da eşik değerleri yer almaktadır.

Tablo 4.7. Giriş nöronları ile gizli katman nöronları arasındaki ağırlık değerleri

Giriş Nöronları ile Gizli Katman Nöronları Arasındaki Ağırlık Değerleri								
	1	2	3	4	5	6	7	8
1	1,177	-1,886	-0,312	-0,059	-1,884	-1,164	-1,906	-1,187
2	0,476	0,475	2,197	-1,662	-0,287	0,069	2,225	1,380
3	-0,086	0,769	-1,828	1,878	1,285	-1,096	0,190	1,987
4	-0,643	-1,980	-0,847	1,803	1,941	0,477	-0,442	-0,981
5	-1,707	-1,961	1,217	-0,531	-0,030	2,036	0,856	1,159
6	-1,025	-1,516	0,277	1,260	1,199	-1,752	2,001	1,048
7	-1,731	1,549	-0,715	-0,084	0,795	2,666	-0,587	-1,257
8	-1,405	-0,664	2,055	-1,801	1,335	-3,020	-0,477	0,140
9	-1,776	-0,633	-1,949	1,231	-1,450	-1,493	0,178	1,917
10	1,697	0,244	-0,933	-1,828	-0,107	0,794	1,360	2,141
11	2,015	0,928	1,674	1,906	-0,936	-1,535	0,417	0,871
12	-1,392	-0,672	0,876	-2,420	-0,970	-2,012	-0,549	-0,655
13	0,880	-0,487	0,834	-0,921	2,144	0,669	1,551	-2,078

Tablo 4.8. Gizli katmandaki nöronların eşik değerleri

Gizli Katmandaki Nöronlar	Eşik Değerleri
1	-38,781
2	-31,771
3	26,694
4	2,306
5	0,996
6	0,380
7	0,071
8	-0,338
9	-16,189
10	21,832
11	26,416
12	-33,658
13	3,858

Tablo 4.9. Gizli katmandaki nöronlar ile çıkış katmanındaki nöron arasındaki ağırlık değerleri

Gizli katmandaki nöronlar ile çıkış katmanındaki nöron arasındaki ağırlık değerleri													
	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0,446	0,416	0,071	0,230	0,258	0,149	-1,571	-2,128	-1,249	-0,117	-0,201	0,885	-0,537

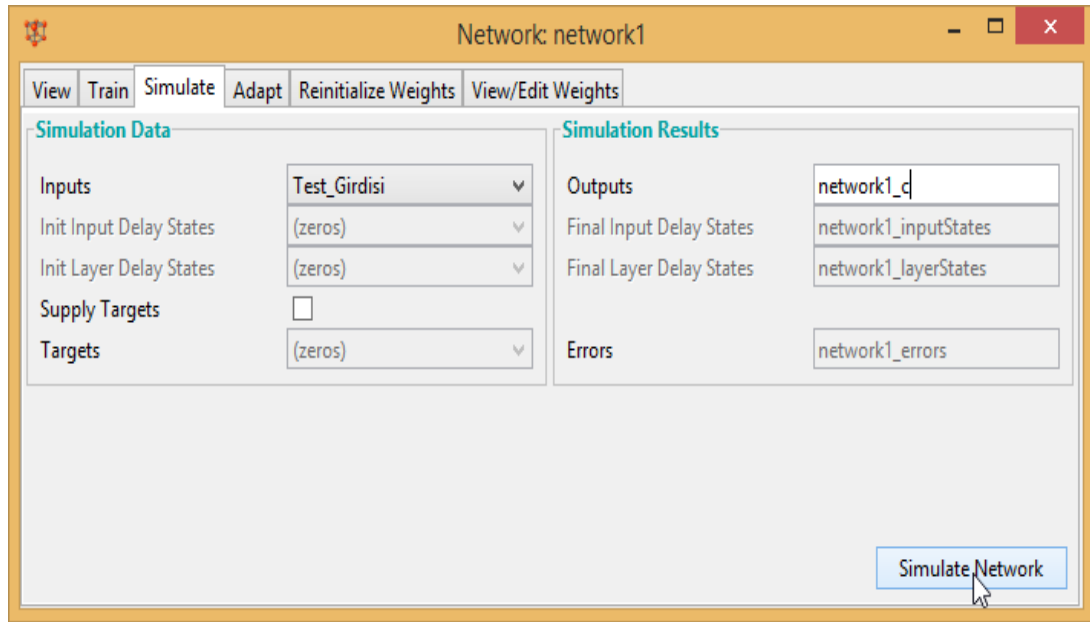
Tablo 4.10. Çıkış katmanındaki nöronun eşik değeri

Çıkış katmanındaki nöron	Eşik değeri
1	1,0725

Ağın eğitilmesinden sonra ağın öğrenip öğrenmediğini ölçmek için denemeler yapılarak ağın testi yapılmıştır. Test aşaması sırasında ağın eğitilirken hiç görmediği, test için ayırdığımız 36 adet veri kullanılmıştır. Bu veriler ağa gösterilir ve ağ eğitimi sırasında, ağın belirlemiş olduğu ağırlık ve eşik değerlerini kullanarak daha önce görmediği bu veriler için çıktılar üretir [12].

4.5. Sonuçların Test Edilmesi ve Değerlendirilmesi

Ağ eğitildikten sonra bu ekranda “Simulate” sekmesinden test girdi seti için ağın tahmini test verilerini üretmesi sağlanır. Şekil 4.14.’de “Simulate” penceresi yer almaktadır. Burada test girdi verisi seçilir ve “Simulate Network” butonuna basılarak ağın test edilmesi işlemi gerçekleştirilmektedir.



Şekil 4.14. Matlab'ta YSA test ekranı

Test işleminden sonra ağı tahmin olarak verdiği test çıktı verileri ile gerçek değerlerin karşılaştırılması gerekmektedir. Buna göre MSE değeri 0,0024 olarak bulunmuştur. Aşağıdaki Tablo 4.11.'de tahmini ve gerçek değerlerin toplam miktarları yer almaktadır. Test verilerinin toplam adeti ile tahmin verilerinin toplam adeti arasında %5,35 'lik bir sapma vardır. Tablo 4.12.'de de gerçek değerler ile çıktı tahmin değerlerinin kıyaslanması yer almaktadır.


Tablo 4.11. YSA'ya göre tahmin performansı

Tahmini Değer (Toplam)	Gerçek Değer (Toplam)	Toplam Sapma %
2.181.406	2.304.587	5,35%
MSE	MAD	MAPE
21.742	14.241	23,48

Tablo 4.12. YSA sonucu bulunan tahmini değerler ile gerçek değerlerin karşılaştırılması

Test Kümesi			
Fiili Değer (Normalize)	Tahmini Değer (Normalize)	Gerçek Değer	Tahmini Değer
0,2692	0,256	76.985	71.478
0,1972	0,195	46.952	46.035
0,2183	0,204	55.773	49.789
0,3833	0,214	124.575	53.960
0,2299	0,219	60.605	56.046
0,3727	0,229	120.141	60.216
0,2117	0,228	52.997	59.799
0,237	0,228	63.547	59.799
0,2093	0,16	51.992	31.437
0,2061	0,211	50.666	52.709
0,2027	0,201	49.247	48.538
0,2016	0,208	48.773	51.458
0,141	0,227	23.529	59.382
0,1898	0,189	43.880	43.533
0,2371	0,21	63.615	52.292
0,3284	0,218	101.680	55.628
0,2635	0,226	74.585	58.965
0,2293	0,228	60.335	59.799
0,2758	0,233	79.740	61.885
0,2371	0,235	63.615	62.719
0,1372	0,204	21.940	49.789
0,2758	0,231	79.740	61.051
0,203	0,227	49.365	59.382
0,2258	0,227	58.875	59.382
0,2619	0,232	73.950	61.468
0,2163	0,231	54.929	61.051
0,1935	0,23	45.408	60.634
0,2558	0,228	71.400	59.799
0,2962	0,227	88.228	59.382
0,2045	0,217	50.012	55.211
0,2223	0,218	57.432	55.628
0,2086	0,23	51.696	60.634
0,2261	0,231	58.996	61.051
0,2403	0,225	64.940	58.548
0,2818	0,228	82.222	59.799
0,2818	0,229	82.222	60.216

Şekil 4.15.'de test kümesi için ayırdığımız 36 adet verinin gerçek değerleri ile YSA ağının üretmiş olduğu tahmini değerlerin grafiksel gösterimi yer almaktadır. Grafikten de görüleceği üzere fiili değerler iyi bir şekilde tahmin edilmiştir.



Şekil 4.15. YSA ile bulunan tahmini değerler ile gerçek değerlerin grafik gösterimi

4.6. Çoklu Regresyon Analizi ile Talep Tahmini Uygulaması

Bir bağımlı değişkene etki eden çok sayıda bağımsız değişkeni analize dahil ederek çoklu regresyon modeli uygulanabilir. Uygulamamızda motor yatağı satışına etki eden 8 adet değişken mevcuttur. Her bir değişkenin motor yatağı satışına etki miktarını bulmak, gelecek dönemlere ait tahmin yapabilmemizi sağlayacaktır. EK-1' de tüm bağımsız değişkenler yer almaktadır.

Çoklu regresyon analizi uygulaması excelde "Veri" kısmında yer alan "Veri Çözümleme" aracıyla yapıldı. Ayrıca aynı uygulama Minitab 17 programıyla da gerçekleştirildi ve aynı sonuca ulaşıldı. Excelde yapılan çoklu regresyon analizi çıktısı aşağıdaki gibidir. Çoklu regresyon katsayısı 0.645 olarak bulunmuştur. Verilmiş olan bağımsız değişkenler, motor yatağı satışını %64 oranında etkilemektedir. Tablo 4.13' de regresyon sonuçları yer almaktadır.

Tablo 4.13. Excelde regresyon istatistikleri

Regresyon İstatistikleri								
Çoklu R	0,645							
R Kare	0,415							
Ayarlı R Kare	0,361							
Standart Hata	50072							
Gözlem	95							
ANOVA								
	df	SS	MS	F	Anlamlılık F			
Regresyon	8	1,53203E+11	19150319555	7,638032728	1,13344E-07			
Fark	86	2,15622E+11	2507231932					
Toplam	94	3,68825E+11						
	Katsayılar	Standart Hata	t Stat	P-değeri	Düşük %95	Yüksek %95	Düşük 95,0%	Yüksek 95,0%
Kesişim	-72954,284	170206,2055	-0,428622942	0,669269333	-411313,0156	265404,4467	-411313,0156	265404,4467
X Değişkeni 1	0,042	0,125596862	0,335836939	0,737811793	-0,207498227	0,291858358	-0,207498227	0,291858358
X Değişkeni 2	-255370,133	46743,82987	-5,463183771	4,47899E-07	-348293,7892	-162446,4763	-348293,7892	-162446,4763
X Değişkeni 3	-6,304	7,942466321	-0,79366058	0,429577467	-22,09272259	9,485477741	-22,09272259	9,485477741
X Değişkeni 4	56,542	40,17359348	1,407429725	0,162904134	-23,32094946	136,4039687	-23,32094946	136,4039687
X Değişkeni 5	-0,001	0,00036431	-2,194636525	0,030884923	-0,001523752	-7,53037E-05	-0,001523752	-7,53037E-05
X Değişkeni 6	-2676,251	1689,838496	-1,583731615	0,116925486	-6035,538331	683,0370309	-6035,538331	683,0370309
X Değişkeni 7	6335,123	1956,902794	3,237321097	0,001714598	2444,928776	10225,31662	2444,928776	10225,31662
X Değişkeni 8	3894,747	2323,527468	1,676221471	0,097326746	-724,2730106	8513,766269	-724,2730106	8513,766269

Çoklu regresyon denklemi Denklem 4.1'deki gibi bulunmuştur. Traktör araç parkı sayısı, ihracat adeti, ÜFE ve faiz oranı satışı olumlu etkilerken, dolar kuru, traktör üretim adeti, GSYH, TÜFE satışı olumsuz etkilemektedir.

$$Y = \text{Araç_parki} * 0.0422 - \text{Dolar_kuru} * 255370.1327 - \text{Uretim_adeti} * 6.3036 + \text{Ihracat_adeti} * 56.5415 - \text{GSYH} * 0.000799 - \text{TUFE} * 2676.2506 + \text{UFE} * 6335.1227 + \text{Faiz_oranu} * 3894.7466 \quad (4.1)$$

Çoklu regresyon denklemi sonucunda test girdilerine ait tahmini çıktı değerleri Tablo 4.14.'deki gibidir:

Tablo 4.14. Çoklu regresyon ile bulunan tahmini deęerler

Fiili Deęerler	Tahmini Deęerler
76.985	113.902
46.952	81.201
55.773	132.947
124.575	121.192
60.605	102.404
120.141	109.874
52.997	74.873
63.547	58.138
51.992	47.388
50.666	60.345
49.247	67.899
48.773	78.250
23.529	98.112
43.880	51.513
63.615	79.588
101.680	74.512
74.585	39.154
60.335	42.148
79.740	38.304
63.615	10.405
21.940	7.761
79.740	12.936
49.365	17.407
58.875	38.403
73.950	47.103
54.929	2.124
45.408	55.983
71.400	56.919
88.228	50.498
50.012	81.729
57.432	71.677
51.696	30.110
58.996	17.052
64.940	39.091
82.222	65.401
82.222	41.773

Yapılan uygulama sonucunda test verilerine ait toplam tahmini deęer ile toplam gerek deęerlerin sapması % 8.09 olarak hesaplanmıřtır. MAPE deęeri % 52.56' dir. Tablo 4.15.'de bu sonular verilmektedir.

Tablo 4.15. Çoklu regresyon sonuçlarına göre bulunan tahmini değerler toplamı

Tahmini Değer (Toplam)	Gerçek Değer (Toplam)	Tahminleme Hatası%
2.118.113	2.304.587	8,09%
MSE	MAD	MAPE
1.175.650.133	28.766	52,56%

4.7. Zaman Serileri Analizi ile Talep Tahmini Uygulaması

Zaman serisi, geçmiş dönemlere ait veriler incelenerek, belli bir eğilim olup olmadığının belirlenip, geleceğe yönelik tahmin yapılmasıdır. Zaman serileri analizi zaman içinde düzenli aralıklarla gözlemlenen verilerin istatistiksel olarak incelenmesini ve gelecek dönemlerde elde edilebilecek verilerin öngörüsünün güvenilir bir şekilde yapılabilmesini içermektedir. Zaman serisine ait talep tahmini uygulaması Minitab 17 programında gerçekleştirilmiştir.

4.7.1. Hareketli ortalama yöntemi

Gelecek dönemin tahminini, son n dönemde gerçekleşen taleplerin ortalaması olarak bulunur. Uygulama olarak son üç döneme ait satışların ortalamasını, bir sonraki dönemin talep tahmin değeri olarak alındı. Tablo 4.16' da son 36 aya ait tahmin edilen değerler ve hata değerleri gösterilmiştir. MAPE değeri % 32.2 olarak bulunmuştur.


Tablo 4.16. Hareketli ortalama yöntemine göre bulunan tahmini değerler

No	Satış	Tahmin	MAPE %	No	Satış	Tahmin	MAPE %
1	76.985	65691	0,1467	19	79.740	78867	0,0109
2	46.952	59602	0,2694	20	63.615	71553	0,1248
3	55.773	61278	0,0987	21	21.940	67897	2,0947
4	124.575	59903	0,5191	22	79.740	55098	0,3090
5	60.605	75767	0,2502	23	49.365	55098	0,1161
6	120.141	80318	0,3315	24	58.875	50348	0,1448
7	52.997	101774	0,9204	25	73.950	62660	0,1527
8	63.547	77914	0,2261	26	54.929	60730	0,1056
9	51.992	78895	0,5174	27	45.408	62585	0,3783
10	50.666	56179	0,1088	28	71.400	58096	0,1863

Tablo 4.16. Hareketli ortalama yöntemine göre bulunan tahmini değerler (Devamı)

No	Satış	Tahmin	MAPE	No	Satış	Tahmin	MAPE
11	49.247	55402	0,1250	29	88.228	57246	0,3512
12	48.773	50635	0,0382	30	50.012	68345	0,3666
13	23.529	49562	1,1064	31	57.432	69880	0,2167
14	43.880	40516	0,0767	32	51.696	65224	0,2617
15	63.615	38727	0,3912	33	58.996	53047	0,1008
16	101.680	43675	0,5705	34	64.940	56041	0,1370
17	74.585	69725	0,0652	35	82.222	58544	0,2880
18	60.335	79960	0,3253	36	82.222	68719	0,1642

Şekil 4.16.'da hareketli ortalama yöntemine tahmin edilen değerler ile gerçek değerlerin grafiksel gösterimi yer almaktadır. Burada yer alan MAPE, MAD ve MSE değerleri 2004-2014 yılları arasındaki 131 adet verinin ortalama hata değerlerini ifade etmektedir.



Şekil 4.16. Hareketli ortalama yöntemine göre bulunan tahmini ve gerçek değerlerin gösterilmesi

4.7.2. Basit üssel düzgünleştirme yöntemi


Üssel düzgünleştirme yöntemi, verilerdeki son değişim ve sıçramaları dikkate alarak tahminlerin veya öngörülerin devamlı güncelleştirildiği bir yöntemdir. Bu yöntemde, gelecek dönemin tahmininin hesabında, son döneme ait tahmin ile bu tahminden elde edilen hatanın bir kısmı kullanılmaktadır.

Basit üssel düzgünleştirme yöntemine göre tahmin edilen değerler ve hata değerleri Tablo 4.17.'de gösterilmektedir. Düzgünleştirme katsayısı olarak Minitab programının önerdiği değer alınmıştır. Bu değer α 0.582146'dir. MAPE değeri olarak % 34.3 bulunmuştur.

Tablo 4.17. Basit üssel düzgünleştirme yöntemiyle bulunan tahmini değerler

No	Satış	Tahmin	MAPE	No	Satış	Tahmin	MAPE
1	76.985	59037	0,2331	19	79.740	67522	0,1532
2	46.952	69485	0,4799	20	63.615	74635	0,1732
3	55.773	56368	0,0107	21	21.940	68220	2,1094
4	124.575	56022	0,5503	22	79.740	41278	0,4823
5	60.605	95930	0,5829	23	49.365	63669	0,2898
6	120.141	75366	0,3727	24	58.875	55342	0,0600
7	52.997	101431	0,9139	25	73.950	57399	0,2238
8	63.547	73236	0,1525	26	54.929	67034	0,2204
9	51.992	67595	0,3001	27	45.408	59987	0,3211
10	50.666	58512	0,1549	28	71.400	51500	0,2787
11	49.247	53944	0,0954	29	88.228	63085	0,2850
12	48.773	51210	0,0500	30	50.012	77722	0,5541
13	23.529	49791	1,1162	31	57.432	61591	0,0724
14	43.880	34503	0,2137	32	51.696	59170	0,1446
15	63.615	39962	0,3718	33	58.996	54819	0,0708
16	101.680	53731	0,4716	34	64.940	57251	0,1184
17	74.585	81644	0,0946	35	82.222	61727	0,2493
18	60.335	77535	0,2851	36	82.222	73658	0,1042

Şekil 4.17.'de basit üssel düzgünleştirme yöntemine göre tahmin edilen değerler ile gerçek değerlerin grafiksel gösterimi yer almaktadır. Burada yer alan MAPE, MAD ve MSE değerleri 2004-2014 yılları arasındaki 131 adet verinin ortalama hata değerlerini ifade etmektedir.



Şekil 4.17. Basit üssel düzgünleştirme yöntemine göre bulunan tahmini ve gerçek değerlerin gösterilmesi

4.7.3. Holt lineer ikili üssel düzgünleştirme yöntemi

Trende sahip mevsimsel dalgalanması olmayan serilerin tahmin işleminde bu yöntem kullanılmaktadır. Bu yöntemi, zaman serisinin bir trende sahip olması durumunda geleceğe yönelik tahmin yapmak için kullanılabilir.

Holt lineer ikili üssel düzgünleştirme yöntemine göre tahmin edilen değerler ve hata değerleri Tablo 4.18.'de gösterilmektedir. Düzgünleştirme katsayısı olarak Minitab programının önerdiği değer alınmıştır. MAPE değeri olarak % 40.07 bulunmuştur.

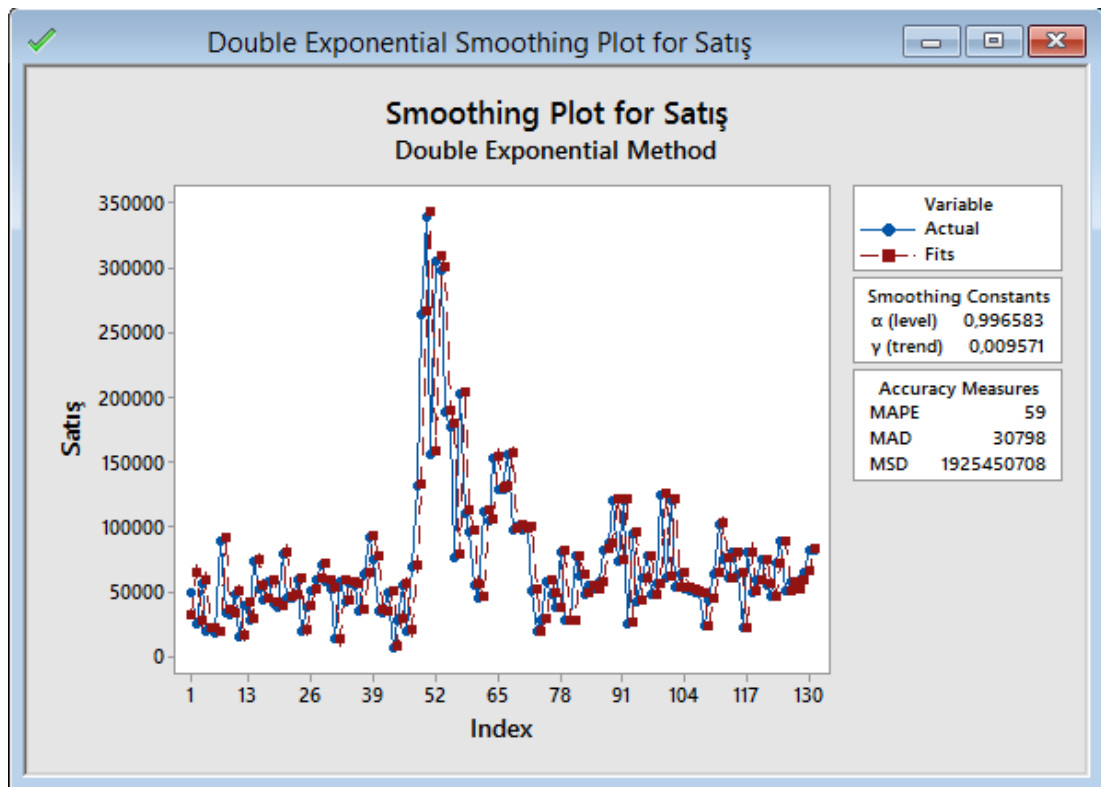
Tablo 4.18. Holt lineer ikili üssel düzgünleştirme yöntemiyle bulunan tahmini değerler

No	Satış	Tahmin	MAPE	No	Satış	Tahmin	MAPE
1	76.985	60554	0,2134	19	79.740	60986	0,2352
2	46.952	77802	0,6571	20	63.615	80455	0,2647
3	55.773	47636	0,1459	21	21.940	64291	1,9303
4	124.575	56401	0,5473	22	79.740	22299	0,7204
5	60.605	125648	1,0732	23	49.365	80306	0,6268
6	120.141	61513	0,4880	24	58.875	49938	0,1518
7	52.997	121186	1,2867	25	73.950	59397	0,1968
8	63.547	53825	0,1530	26	54.929	74591	0,3580
9	51.992	64201	0,2348	27	45.408	55500	0,2223
10	50.666	52605	0,0383	28	71.400	45850	0,3578

Tablo 4.18. Holt lineer ikili üssel düzgünleştirme yöntemiyle bulunan tahmini değerler (Devamı)

No	Satış	Tahmin	MAPE	No	Satış	Tahmin	MAPE
11	49.247	51225	0,0402	29	88.228	71964	0,1843
12	48.773	49787	0,0208	30	50.012	88979	0,7792
13	23.529	49300	1,0953	31	57.432	50580	0,1193
14	43.880	23895	0,4554	32	51.696	57908	0,1202
15	63.615	44281	0,3039	33	58.996	52158	0,1159
16	101.680	64202	0,3686	34	64.940	59478	0,0841
17	74.585	102563	0,3751	35	82.222	65479	0,2036
18	60.335	75424	0,2501	36	82.222	82882	0,0080

Şekil 4.18.'de holt lineer ikili üssel düzgünleştirme yöntemine göre tahmin edilen değerler ile gerçek değerlerin grafiksel gösterimi yer almaktadır. Burada yer alan MAPE, MAD ve MSE değerleri 2004-2014 yılları arasındaki 131 adet verinin ortalama hata değerlerini ifade etmektedir.



Şekil 4.18. Holt lineer ikili üssel düzgünleştirme yöntemine göre bulunan tahmini ve gerçek değerler

4.7.4. Winters üssel düzgünleştirme yöntemi


Zaman serisinin trend bileşeni ile birlikte mevsimsellik de içerdiği durumlarda kullanılır. Bu durumda talep, doğrusal bir yapı göstermemektedir. Tahmin formülasyonunda trend bileşeni ile birlikte mevsimsellik bileşeni de vardır.

Winters üssel düzgünleştirme yöntemine göre tahmin edilen değerler ve hata değerleri Tablo 4.19.'da gösterilmektedir. MAPE değeri olarak %34.57 bulunmuştur.

Tablo 4.19. Winters üssel düzgünleştirme yöntemiyle bulunan tahmini değerler

No	Satış	Tahmin	MAPE	No	Satış	Tahmin	MAPE
1	76,985	78,076	0,0142	19	79,740	76,168	0,0448
2	46,952	60,691	0,2926	20	63,615	69,688	0,0955
3	55,773	47,960	0,1401	21	21,940	69,494	2,1675
4	124,575	71,824	0,4234	22	79,740	54,489	0,3167
5	60,605	71,077	0,1728	23	49,365	55,543	0,1251
6	120,141	64,239	0,4653	24	58,875	45,347	0,2298
7	52,997	136,435	1,5744	25	73,950	72,513	0,0194
8	63,547	69,147	0,0881	26	54,929	57,927	0,0546
9	51,992	73,603	0,4157	27	45,408	52,435	0,1548
10	50,666	75,312	0,4864	28	71,400	67,406	0,0559
11	49,247	48,999	0,0050	29	88,228	53,686	0,3915
12	48,773	50,026	0,0257	30	50,012	62,503	0,2498
13	23,529	55,851	1,3737	31	57,432	82,325	0,4334
14	43,880	33,014	0,2476	32	51,696	60,935	0,1787
15	63,615	36,834	0,4210	33	58,996	45,400	0,2305
16	101,680	46,931	0,5384	34	64,940	70,515	0,0858
17	74,585	70,339	0,0569	35	82,222	59,617	0,2749
18	60,335	79,954	0,3252	36	82,222	60,088	0,2692

Şekil 4.19.'da Winters üssel düzgünleştirme yöntemine göre tahmin edilen değerler ile gerçek değerlerin grafiksel gösterimi yer almaktadır. Burada yer alan MAPE, MAD ve MSE değerleri 2004-2014 yılları arasındaki 131 adet verinin ortalama hata değerlerini ifade etmektedir.



Şekil 4.19. Winters üssel düzgünleştirme yöntemine göre bulunan tahmini ve gerçek değerlerin gösterilmesi

4.8. Tahmin Yöntemlerinin Karşılaştırılması

YSA, çoklu regresyon ve zaman serilerine bağlı yapılan tahmin sonuçlarının karşılaştırılması Tablo 4.20.'de görüldüğü gibidir. Burada her bir test verisinin gerçek değeri ile tahmini değerlerinin arasındaki farklar gösterilmektedir. Performans fonksiyonu olarak ortalama hata değeri, MAPE, alınmıştır. Aşağıdaki tablodan da görüleceği üzere en iyi sonucu YSA ile bulunan tahmin değerleri vermiştir. (MAPE= %23.5)

Tablo 4.20. Tahmin yöntemlerinin sonuçlarının karşılaştırılması

Test Verileri	MAPE Değerleri					
	YSA	Regresyon	Hareketli Ortalama	Basit Üssel D.	Holt İkili Üssel D.	Winters Üssel D.
1	0,07	0,48	0,15	0,23	0,21	0,01
2	0,02	0,73	0,27	0,48	0,66	0,29
3	0,11	1,38	0,10	0,01	0,15	0,14
4	0,57	0,03	0,52	0,55	0,55	0,42
5	0,08	0,69	0,25	0,58	1,07	0,17
6	0,50	0,09	0,33	0,37	0,49	0,47
7	0,13	0,41	0,92	0,91	1,29	1,57
8	0,06	0,09	0,23	0,15	0,15	0,09
9	0,40	0,09	0,52	0,30	0,23	0,42
10	0,04	0,19	0,11	0,15	0,04	0,49
11	0,01	0,38	0,12	0,10	0,04	0,01
12	0,06	0,60	0,04	0,05	0,02	0,03
13	1,52	3,17	1,11	1,12	1,10	1,37

Tablo 4.20. Tahmin yöntemlerinin sonuçlarının karşılaştırılması (Devamı)

Test Verileri	MAPE Değerleri					
	YSA	Regresyon	Hareketli Ortalama	Basit Üssel D.	Holt İkili Üssel D.	Winters Üssel D.
28	0,16	0,20	0,19	0,28	0,36	0,06
29	0,33	0,43	0,35	0,28	0,18	0,39
30	0,10	0,63	0,37	0,55	0,78	0,25
31	0,03	0,25	0,22	0,07	0,12	0,43
32	0,17	0,42	0,26	0,14	0,12	0,18
33	0,03	0,71	0,10	0,07	0,12	0,23
34	0,10	0,40	0,14	0,12	0,08	0,09
35	0,27	0,20	0,29	0,25	0,20	0,27
36	0,27	0,49	0,16	0,10	0,01	0,27
MAPE %	23,5%	52,6%	32,2%	34,3%	40,1%	34,6%

4.9. Sonuç ve Öneriler

Tahmin, gelecekte neyin nasıl olacağını önceden kestirilmesidir. Hemen hemen bütün yönetsel kararlar ileriye yönelik tahminlere dayanmaktadır. Bu yüzden tüm firmalar gelecekte karşılaşılabileceği belirsiz durumları önceden tahmin ederek, buna uygun önlemler ve iyileştirmeler yapmak durumundadırlar. Dolayısıyla uygulamasını yaptığımız işletme probleminin çözümünde bir tahmin aracı olarak yapay sinir ağlarına ait geri yayılım algoritması denenmiştir. YSA teorisi araştırılarak, tahmin üzerinde yapılmış olan uygulamalar incelenmiştir. Tahmin çalışmasının başarısını ölçebilmek için çoklu regresyon modeli ve zaman serileri analizi ile bulunan tahmin sonuçları YSA tahmin sonuçları ile karşılaştırılmıştır.

YSA modeli aralarında lineer ilişki bulunmayan birçok değişkene bağlı problemin çözümünde olumlu sonuçlar vermektedir. Geleneksel istatistiksel analizler genelde göstergelerin normal dağılım gösterdiğini savunmaktadır. Regresyon analizi de bağımlı ve bağımsız değişkenler arasında doğrusal bir ilişkinin olduğunu varsayar. Bu da tahmin doğruluğunu etkileyen önemli bir hatadır. Geçmişte yapılan araştırmalar bu ilişkinin doğrusal olmadığını göstermektedir. Bu durumda tahmin araştırmalarında, sıklıkla kullanılan regresyon analizinin varsayımlarının gerçekleşmediği durumlarda YSA analizinin kullanılması daha doğru sonuçlar vermektedir. Zaman serileri analizi ise, belirli bir zaman aralıklarında gözlenen bir

olay hakkında, gözlenen serinin yapısını veren stokastik süreci modellemeyi ve geçmiş dönemlere ilişkin gözlem değerleri yardımıyla geleceğe yönelik tahminler yapmayı amaçlayan bir metottur. Kullanılan zaman serisindeki ilişkinin doğrusal ya da doğrusal olmaması konusunda kesin bir kanıya varılamamaktadır. Bu yüzden zaman serileri tek başına çok doğru bir sonuç verdiği düşünülemez.

Uygulama çalışmamızda, 2004-2014 yılları arasında gerçekleşen motor yatağı satış verileri adet cinsinden verilmiştir. Satışları etkileyen faktörler, çalışma öncesinde görüşülen uzman kişilerin görüşleri alınarak belirlenmiştir. Bu faktörlere ait bilgiler, TÜİK, IMKB, OSD vb. kurum kaynaklarından elde edilmiştir. Motor yatağı satışının talep tahminin hesaplanmasında sadece yurt içi traktör üreten firmalara verilen motor yatağının adetleri dikkate alınmıştır. Yurt içi traktör üreten firmalara motor yatağı satışını etkileyen 8 ana faktör olduğunu düşünülmüştür. Bunlar; traktör araç parkı, dolar kuru, traktör üretim adeti, traktör ihracat adeti, GSYH, Tüfe, Üfe ve faiz oranıdır. Bu bağımsız değişkenlerin motor yatağının satışını nasıl etkilediği yapılan çalışmalar sonucunda bulunmuştur. Ayrıca satışları etkileyen bir diğer etken de o ay içinde kampanya olup olmamasıdır. O ay kampanya yapılmışsa satış adetleri artmaktadır. Otomotiv sektörünün yaz dönemlerinde duruş yapmasından ötürü, duruş ayından bir önceki ve bir sonraki aylarda satış adetleri artmaktadır. Bu yüzden bazı aylar için hesaplanan tahminlerin hataları çok fazladır. Bu veriler (0.1, 0.9) aralığında normalleştirilerek eğitim ve test amacıyla ağa sunulmuştur. 2004 - 2011 (aralık) yılları arasındaki 95 adet veri ağın eğitimi için, 2012-2014 yılları arasındaki 36 adet veri ise ağın test edilmesi için kullanılmıştır. Yapılan tahmin sonucunda MAPE= 0.23 lik bir hatayla 0.77 başarı elde edilmiştir.

Ayrıca tahmin performansının ölçülmesi amacıyla çoklu regresyon yöntemi, hareketli ortalama yöntemi, üssel düzeltme yöntemleri ile de talep tahmini yapılmıştır. Yapılan çalışmalar sonucunda YSA tekniğinin daha başarılı olduğu görülmüş ve test verilerine ait değerler için tahmini değerler bulunmuştur. Bu değerler gerçek verilerle karşılaştırılmış ve gerçek değerleri ne derece yaklaştığı hesaplanmıştır. (YSA ile bulunan MAPE değeri %23.48, çoklu regresyon ile bulunan MAPE değeri %52.6, hareketli ortalama ile bulunan MAPE değeri % 32.2, basit üssel düzgünleştirme yöntemiyle bulunan MAPE değeri % 34.3, Holt ikili üssel düzgünleştirme

yöntemiyle bulunan MAPE değeri % 40.1 ve Winters üssel düzgünleştirme yöntemiyle bulunan MAPE değeri % 34.6' dır. Tablo 4.20.' yer almaktadır.) En düşük hata değerini veren yapay sinir ağları ile bulunan değerdir.

İleriye yönelik yapılacak çalışmalar için, farklı mimariye sahip YSA modelleri kullanılarak tahminler önerilebilir. Ayrıca YSA ile zaman serilerinin birlikte kullanıldığı melez yöntemlerde kullanılarak tahmin performansı incelenebilir. Yapay sinir ağları hem doğrusal hem de doğrusal olmayan ilişkileri modelleyebilmesine karşılık, her veri seti için aynı etkinlikte sonuçlar sağlayamamaktadır. Melez modeller doğrusal ve doğrusal olmayan bileşenleri ayrı ayrı modelleyebilmektedirler. Yapılan çalışmalar, tek bir yöntemle tahmin etmek yerine, verilerdeki farklı fonksiyonel ilişkileri modelleyebilen birden fazla yöntem birleştirilerek tahmin yapmanın daha iyi sonuçlar verdiğini göstermektedir.

KAYNAKLAR

- [1] Serttaş, Z. Türkiye’ de Perakende Sektöründe Talebi Etkileyen Etmenler ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi, 2011.
- [2] Yazıcıoğlu, N. Yapay Zeka İle Talep Tahmini, Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi, 2010.
- [3] Olgun, S. Tedarik Zinciri Yönetiminde Talep Tahmini Yöntemler ve Yapay Zeka Tabanlı Bir Talep Tahmini Modelinin Uygulanması, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi, 2009.
- [4] Yücesoy, M. Temizlik Sektöründe Yapay Sinir Ağları ile Talep Tahmini, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi, 2011.
- [5] Özer, K. İstanbul Deniz Otobüslerinin Bir Hattında Yolcu Talep Tahmini, Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Ana Bilim Dalı, Yüksek Lisans Tezi, 2009.
- [6] Aikeshan, A. Bulanık Doğrusal Regresyon Yöntemi ile Talep Tahmini: Medikal Asistans Firmasında Bir Uygulama, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İşletme Mühendisliği Ana Bilim Dalı, Yüksek Lisans Tezi, 2014.
- [7] Öztemel, E. 2015. Yapay Sinir Ağları, 3.Cilt, Papatya Yayıncılık, 1-232.
- [8] Karahan, M. İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Ana Bilim Dalı, Doktora Tezi, 2011.
- [9] Gürsoy, A. Yapay Sinir Ağları Yaklaşımıyla Lastik Kalıbı Maliyetinin Tahmin Edilmesi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi, 2012.
- [10] Deveci, M. Yapay Sinir Ağları ve Bekleme Süresinin Tahmininde Kullanılması, Gazi Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Ana Bilim Dalı, Üretim Yönetimi Bilim Dalı, Yüksek Lisans Tezi, 2012.

- [11] Kölmek, M.A. Türkiye Elektrik Dengeleme ve Uzlaştırma Piyasasındaki Sistem Gün Öncesi Fiyatının Yapay Sinir Ağları Kullanarak Modellenmesi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik Mühendisliği Ana Bilim Dalı, Yüksek Lisans Tezi, 2012.
- [12] Kargı, V. 2015. Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama, 1.Cilt, Ekin Yayınevi, 1-163.
- [13] Doğan, M. Ekonomik Bir Büyüme Modelinin Yapay Sinir Ağları ile Tahmini ve Türkiye’ de Uygulanması, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik Bölümü, Yüksek Lisans Tezi, 2012.
- [14] Elmas, Ç. 2015. Yapay Zeka Uygulamaları, 2.Cilt, Seçkin Yayıncılık, 1- 420.
- [15] Çuhadar, M. Turizm Sektöründe Talep Tahmini için Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi, Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Doktora Tezi, 2006.
- [16] Karaatlı, M. Yapay Sinir Ağları Yöntemi ile Tahmin (İMKB’ de Bir Uygulama), Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Yüksek Lisans Tezi, 2003.
- [17] Es, H. Yapay Sinir Ağları ile Türkiye Net Enerji Talep Tahmini, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Ana Bilim Dalı, Yüksek Lisans Tezi, 2013.
- [18] Bulgan, A. Pnömatik Devrelerde Optimum Tasarım ve Yapay Sinir Ağları ile Titreşim Analizi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Makina Mühendisliği Bölümü, Yüksek Lisans Tezi, 2013.
- [19] Kasaplı, K. İçme Suyu Şebekelerinde Maliyet Tahmini Amacıyla Yapay Sinir Ağları Kullanımı, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İnşaat Mühendisliği Bölümü, Yüksek Lisans Tezi, 2014.
- [20] Küçükönder, H. Yapay Sinir Ağları ve Tarımda Bir Uygulama, Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Zootekni Ana Bilim Dalı, Doktora Tezi, 2011.
- [21] Yazıcı, Ü. Yapay Sinir Ağları İle Banka Müşterisi Bekleme Süresi Tahmini, Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi, 2010.
- [22] Sevinçtekin, E. İmalat Sektöründe Yapay Sinir Ağları Uygulaması, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Ana Bilim Dalı, Sistem Mühendisliği Programı, Yüksek Lisans Tezi, 2014.
- [23] Fausett, L. 1994. Fundamentals of Neural Networks Architectures, Algorithms and Applications, Prentice- Hall, Inc. A Paramount Communications

Company Englewood Cliffs, New Jersey.

- [24] Ersöz E., Yaman, N. ve Birgören, B., 2008. Müşteri İlişkileri Yönetiminde Verilerin Yapay Sinir Ağları ile Modellenmesi ve Analizi, Gazi Üniversitesi Mimarlık Mühendislik Fakültesi Dergisi, 23(4): 759-767.
- [25] Hamzaçebi, C. ve Kutay, F., 2004. Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini, Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 19(3):227-233.
- [26] Yakut, E., Elmas, B. ve Yavuz, S., 2014. Yapay Sinir Ağları ve Destek Vektör Makinaları Yöntemleriyle Borsa Endeksi Tahmini, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 19(1): 139-157.
- [27] Özkan, Ö., Group Technology and Cellular Manufacturing with Artificial Neural Networks, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 2010.
- [28] Kızılaslan, R., Forecasting of Short Term and Mid Term İstanbul Natural Gas Consumption Values By Neural Network Algorithms, Fatih Üniversitesi, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi, 2008.
- [29] Akyol, D., Neural Network Based Optimization in Production Scheduling, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi, 2016.
- [30] Cura, T., Karar Verme Aracı Olarak Yapay Sinir Ağları ve Yapay Sinir Ağları ile Portföy Optimizasyonu, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Sayısal Yöntemler Bilim Dalı, Doktora Tezi, 2004.
- [31] <http://www.elektrikport.com/teknik-kutuphane/yapay-sinir-aglari/>, Erişim Tarihi: 06.12.2015.
- [32] Altun, İ. ve DüNDAR, S. 2005. Yapay Sinir Ağları ile Trafik Akım Kontrolü. Deprem Sempozyumu, Kocaeli, 1335-1344.
- [33] <http://www.ibrahimay.net/yazilarim/bilim/3-matlab-ile-yapay-sinir-agi-uygulamasi.html>. Erişim Tarihi: 06.12.2015.
- [34] Erkaymaz, H. ve Yaşar, Ö. 2011. Yapay Sinir Ağları ile Hava Sıcaklığı Tahmini, Fırat Üniversitesi, International Computer & Instructional Technologies Symposium, Elazığ, 1-7.
- [35] Asilkan, Ö. ve Irmak, S. 2009. İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin Edilmesi. Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 14(2): 375-391.

- [36] Emel, G. ve Taşkın, Ç. 2002. Genetik Algoritmalar ve Uygulama Alanları, Uludağ Üniversitesi, İdari ve İktisadi Bilimler Fakültesi Dergisi, 11(1):129-152.
- [37] <http://www.osd.org.tr/> Erişim Tarihi: 04.02.2015.
- [38] <http://www.tuik.gov.tr/> Erişim Tarihi: 04.02.2015.

EKLER

EK 1: Tahminlemede Kullanılan Giriş Verileri

Yıllar	Aylar	Araç Parkı	Dolar Kuru	Üretim Adeti	İhracat Adeti	GSYH	Tüfe	Üfe	Faiz Oranı	Satış
2004	1	1.009.065	1.35	3045	861	119502314	104.81	104.46	28.03	48.632
2004	2	1.009.065	1.33	2845	861	119502314	105.35	106.17	26.36	25.187
2004	3	1.009.065	1.32	3899	861	119502314	106.36	108.40	24.99	56.655
2004	4	1.009.065	1.36	4049	861	130998596	106.89	111.27	23.56	19.655
2004	5	1.009.065	1.51	4183	861	130998596	107.35	111.24	22.76	19.950
2004	6	1.009.065	1.50	4145	861	130998596	107.21	110.06	26.91	18.100
2004	7	1.009.065	1.45	3743	861	157689939	107.72	108.39	28.32	89.411
2004	8	1.199.813	1.48	1952	861	157689939	108.54	109.25	27.8	33.690
2004	9	1.202.547	1.51	3767	861	157689939	109.57	111.26	27.62	31.165
2004	10	1.204.942	1.49	2759	861	150842176	112.03	114.85	27.88	48.107
2004	11	1.207.533	1.45	2430	861	150842176	113.50	115.72	26.01	14.845
2004	12	1.210.283	1.40	1810	861	150842176	113.86	115.87	25.26	39.516
2005	1	1.212.777	1.36	2135	695	141085930	114.49	114.83	24.65	28.051
2005	2	1.214.400	1.31	2735	695	141085930	114.51	114.81	21.93	73.324
2005	3	1.215.508	1.31	3156	695	141085930	114.81	117.25	19.99	52.399
2005	4	1.218.701	1.36	2823	695	153763755	115.63	119.62	19.1	42.581
2005	5	1.222.103	1.37	2886	695	153763755	116.69	119.23	18.39	57.246
2005	6	1.225.393	1.36	3544	695	153763755	116.81	119.64	18.3	40.163
2005	7	1.228.137	1.34	2887	695	181572348	116.14	119.33	18.28	37.055
2005	8	1.231.356	1.34	2945	695	181572348	117.13	121.40	16.29	78.145
2005	9	1.235.413	1.34	3408	695	181572348	118.33	123.40	19.66	44.129
2005	10	1.239.620	1.36	3037	695	172509679	120.45	124.22	19.46	45.259
2005	11	1.243.377	1.36	2612	695	172509679	122.14	121.40	18.71	59.081
2005	12	1.247.767	1.35	2739	695	172509679	122.65	121.14	18.42	18.700
2006	1	1.252.202	1.33	2302	820	160072572	123.57	123.51	17.36	37.269
2006	2	1.254.498	1.33	3297	820	160072572	123.84	123.83	17.51	50.484
2006	3	1.258.004	1.34	3810	820	160072572	124.18	124.14	17.28	58.398
2006	4	1.261.886	1.34	3428	820	183652122	125.84	126.54	16.4	70.604
2006	5	1.267.695	1.43	4207	820	183652122	128.20	130.05	13.47	57.176

Yıllar	Aylar	Araç Parkı	Dolar Kuru	Üretim Adeti	İhracat Adeti	GSYH	Tüfe	Üfe	Faiz Oram	Satış
2006	6	1.271.387	1.43	3620	820	183652122	128.63	135.28	14.58	51.372
2006	7	1.274.009	1.55	2640	820	213295396	129.72	136.45	22.43	12.718
2006	8	1.276.847	1.47	2326	820	213295396	129.15	135.43	22.35	57.869
2006	9	1.279.905	1.48	3493	820	213295396	130.81	135.11	21.41	41.538
2006	10	1.282.966	1.48	2837	820	201370695	132.47	135.73	21.55	55.529
2006	11	1.287.001	1.46	3293	820	201370695	134.18	135.33	22.06	54.284
2006	12	1.290.679	1.43	2829	820	201370695	134.49	135.16	21.45	34.092
2007	1	1.293.650	1.43	2899	773	187950694	135.84	135.09	20.52	63.464
2007	2	1.296.068	1.40	2887	773	187950694	136.42	136.37	21.42	91.278
2007	3	1.299.298	1.41	3002	773	187950694	137.67	137.70	20.53	75.241
2007	4	1.302.095	1.36	2770	773	203279705	139.33	138.80	19.85	34.294
2007	5	1.305.464	1.34	3038	773	203279705	140.03	139.34	19.64	33.066
2007	6	1.308.800	1.32	2716	773	203279705	139.69	139.19	19.21	49.050
2007	7	1.311.448	1.28	2622	773	232256566	138.67	139.28	19.46	6.412
2007	8	1.313.929	1.32	2163	773	232256566	138.70	140.47	18.72	27.280
2007	9	1.317.180	1.26	2934	773	232256566	140.13	141.90	18.32	54.328
2007	10	1.320.234	1.20	2785	773	219691456	142.67	141.71	18.43	18.723
2007	11	1.324.076	1.19	3202	773	219691456	145.45	142.98	17.86	69.184
2007	12	1.327.334	1.18	2520	773	219691456	145.77	143.19	16.99	131.138
2008	1	1.330.361	1.18	2219	894	215605654	146.94	143.80	16.46	264.393
2008	2	1.332.452	1.20	2356	894	215605654	148.84	147.48	16.88	340.083
2008	3	1.336.175	1.24	2854	894	215605654	150.27	152.16	17.51	156.185
2008	4	1.339.416	1.30	2610	894	239363433	152.79	159.00	18.48	306.196
2008	5	1.342.273	1.25	2677	894	239363433	155.07	162.37	18.57	298.194
2008	6	1.344.867	1.23	2597	894	239363433	154.51	162.90	18.8	187.945
2008	7	1.347.323	1.21	2976	894	262392170	155.40	164.93	19.5	177.943
2008	8	1.350.010	1.18	783	894	262392170	155.02	161.07	19.83	76.524
2008	9	1.352.225	1.24	2048	894	262392170	155.72	159.63	19.78	202.714
2008	10	1.354.731	1.50	1161	894	233172993	159.77	160.54	19.46	110.927
2008	11	1.356.873	1.60	1690	894	233172993	161.10	160.49	23.58	95.783
2008	12	1.358.577	1.54	836	894	233172993	160.44	154.80	24.06	54.262
2009	1	1.359.427	1.60	988	769	207925991	160.90	155.16	21.59	45.148
2009	2	1.360.035	1.66	1322	769	207925991	160.35	156.97	21.36	112.060
2009	3	1.360.756	1.71	955	769	207925991	162.12	157.43	20.27	104.440
2009	4	1.360.862	1.61	963	769	228571898	162.15	158.45	18.66	152.640
2009	5	1.361.038	1.56	1041	769	228571898	163.19	158.37	18.47	128.640
2009	6	1.360.485	1.55	1435	769	228571898	163.37	159.86	18.22	129.430
2009	7	1.360.795	1.52	1610	769	261710449	163.78	158.74	18.16	155.747
2009	8	1.361.598	1.49	843	769	261710449	163.29	159.40	17.6	97.600
2009	9	1.362.717	1.49	1111	769	261710449	163.93	160.38	15.96	100.945
2009	10	1.364.199	1.47	1511	769	254350241	167.88	160.84	14.9	96.974

Yıllar	Aylar	Araç Parkı	Dolar Kuru	Üretim Adeti	İhracat Adeti	GSYH	Tüfe	Üfe	Faiz Oranı	Satış
2009	11	1.365.780	1.49	1463	769	254350241	170.01	162.92	14.36	98.520
2009	12	1.368.032	1.51	1619	769	254350241	170.91	163.98	13.7	50.749
2010	1	1.369.185	1.47	1793	628	241026016	174.07	164.94	12.36	18.500
2010	2	1.371.223	1.52	1943	1273	241026016	176.59	167.68	13.63	28.042
2010	3	1.373.675	1.53	2416	992	241026016	177.62	170.94	12.99	57.823
2010	4	1.376.872	1.49	2441	884	265996869	178.68	174.96	11.98	47.471
2010	5	1.379.492	1.55	2793	1126	265996869	178.04	172.95	11.31	37.476
2010	6	1.382.181	1.58	2813	1042	265996869	177.04	172.08	11.7	80.784
2010	7	1.384.173	1.54	3266	815	295995607	176.19	171.81	11.29	27.259
2010	8	1.387.224	1.51	1029	415	295995607	176.90	173.79	11	27.487
2010	9	1.390.006	1.49	2808	711	295995607	179.07	174.67	10.63	76.968
2010	10	1.394.523	1.42	3271	511	295780856	182.35	176.78	10.63	61.622
2010	11	1.398.559	1.44	2972	560	295780856	182.40	176.23	10.43	47.618
2010	12	1.404.872	1.52	2880	601	295780856	181.85	178.54	9.39	54.124
2011	1	1.407.932	1.56	2784	255	289904998	182.60	182.75	10.01	51.414
2011	2	1.413.247	1.59	3181	396	289904998	183.93	185.90	10.44	56.909
2011	3	1.419.265	1.58	3567	624	289904998	184.70	188.17	10.41	82.232
2011	4	1.424.779	1.52	4583	654	317392144	186.30	189.32	10.49	86.798
2011	5	1.430.910	1.58	4490	679	317392144	190.81	189.61	10.85	120.138
2011	6	1.437.463	1.60	4657	980	317392144	188.08	189.62	11.09	73.064
2011	7	1.442.008	1.66	4313	852	351173122	187.31	189.57	11.35	120.338
2011	8	1.446.076	1.76	2035	819	351173122	188.67	192.91	13.05	24.975
2011	9	1.450.285	1.80	3918	1136	351173122	190.09	195.89	13.17	95.251
2011	10	1.456.177	1.83	4137	1026	339242947	196.31	199.03	12.9	41.924
2011	11	1.461.181	1.82	4085	1019	339242947	199.70	200.32	13.85	59.897
2011	12	1.466.208	1.87	3756	1925	339242947	200.85	202.33	11.39	76.985
2012	1	1.468.569	1.84	3767	812	325184111	201.98	203.10	13.9	46.952
2012	2	1.470.233	1.76	4431	1417	325184111	203.12	202.91	15.11	55.773
2012	3	1.474.433	1.79	4774	1423	325184111	203.96	203.64	13.95	124.575
2012	4	1.480.835	1.79	4434	1569	350160525	207.05	203.81	13.21	60.605
2012	5	1.486.894	1.81	4483	1694	350160525	206.61	204.89	12.75	120.141
2012	6	1.491.348	1.82	4654	1432	350160525	204.76	201.83	12.38	52.997
2012	7	1.495.172	1.81	4358	1433	377042315	204.29	201.20	13.08	63.547
2012	8	1.498.324	1.80	693	712	377042315	205.43	201.71	13.66	51.992
2012	9	1.501.921	1.80	3101	1132	377042315	207.55	203.79	13.3	50.666
2012	10	1.505.939	1.80	2691	1220	364411539	211.62	204.15	12.86	49.247
2012	11	1.510.698	1.79	3265	1108	364411539	212.42	207.54	12.46	48.773
2012	12	1.515.421	1.87	1604	1758	364411539	213.23	207.29	11.35	23.529

Yıllar	Aylar	Araç Parkı	Dolar Kuru	Üretim Adeti	İhracat Adeti	GSYH	Tüfe	Üfe	Faiz Oranı	Satış
2013	1	1.517.534	1.77	3010	783	355687372	216.74	206.91	10.56	43.880
2013	2	1.519.992	1.78	3030	1332	355687372	217.39	206.65	11.1	63.615
2013	3	1.524.015	1.81	3316	1340	355687372	218.83	208.33	10.54	101.680
2013	4	1.528.661	1.80	3526	1278	386372813	219.75	207.27	10.52	74.585
2013	5	1.533.579	1.83	3393	1266	386372813	220.07	209.34	10.08	60.335
2013	6	1.536.208	1.90	4001	1352	386372813	221.75	212.39	9.57	79.740
2013	7	1.540.491	1.93	3756	1201	417223007	222.44	214.50	9.78	63.615
2013	8	1.543.767	1.96	1903	749	417223007	222.21	214.59	10.26	21.940
2013	9	1.548.604	2.02	4391	1438	417223007	223.91	216.48	11.41	79.740
2013	10	1.553.291	1.99	3125	1093	405897770	227.94	217.97	11.54	49.365
2013	11	1.558.979	2.03	4185	1580	405897770	227.96	219.31	11.67	58.875
2013	12	1.565.817	2.07	2873	1584	405897770	229.01	221.74	11.04	73.950
2014	1	1.568.065	2.23	3402	961	409203112	233.54	229.10	10.62	54.929
2014	2	1.571.666	2.21	3694	1351	409203112	234.54	232.27	14.97	45.408
2014	3	1.576.193	2.22	4456	1386	409203112	237.18	233.98	15.26	71.400
2014	4	1.581.146	2.13	4548	1245	425916864	240.37	234.18	15.17	88.228
2014	5	1.586.340	2.09	4150	1815	425916864	241.32	232.96	14.49	50.012
2014	6	1.591.423	2.12	4426	1847	425916864	242.07	233.09	13.95	57.432
2014	7	1.595.667	2.12	4003	1547	461654401	243.17	234.79	12.36	51.696
2014	8	1.600.621	2.16	2952	1248	461654401	243.40	235.78	12.79	58.996
2014	9	1.606.383	2.21	5038	1872	461654401	243.74	237.79	12.92	64.940
2014	10	1.612.310	2.26	4103	1678	407309998	248.37	239.97	12.39	82.222
2014	11	1.619.124	2.24	4324	1444	407309998	248.82	237.65	12.73	82.222

ÖZGEÇMİŞ

Meral Sarı, 01.10.1988 tarihinde Kocaeli’de doğdu. İlk, orta ve lise eğitimini Gebze’de tamamladı. 2007 yılında Darıca Neşet Yalçın Süper Lisesi’nde Fen Bilimleri dalından mezun oldu. Yine aynı yıl başladığı Kocaeli Üniversitesi Endüstri Mühendisliği bölümünü 2012 yılında bitirdi. 2012 yılında başladığı Sakarya Üniversitesi, Fen Bilimleri Enstitüsü Yöneylem Araştırması Bölümünde halen yüksek lisans öğrencisidir. 2011-2013 yılları arasında Çelmer Çelik Endüstrisi firmasında Süreç Geliştirme Mühendisi olarak görev yaptı. 2013-2014 yılları arasında Güngör Otomobil Yan Sanayi firmasında Planlama Mühendisi olarak çalıştı. Şuanda Şahin Motor Yatakları firmasında Planlama Mühendisi olarak görev yapmaktadır. Bu süre içerisinde çalışmış olduğu şirketlerde ERP kurulum projesi ve verimlilik artırma çalışmalarında aktif rol aldı.