

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

**ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI  
YÜKSEK LİSANS TEZİ**

**İŞ MAKİNELERİ SEKTÖRÜNDE YAPAY SİNİR AĞLARI İLE TALEP  
TAHMİNİ UYGULAMASI**

**EMRE YANIK**

**HAZİRAN 2019**

## ÖZET

### İŞ MAKİNELERİ SEKTÖRÜNDE YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ UYGULAMASI

YANIK, Emre

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Endüstri Mühendisliği Ana Bilim Dalı, Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Adnan AKTEPE

Haziran 2019, 100 sayfa

Talep tahmin metotları, kalitatif ve kantitatif olarak iki ana başlık altında toplanır. Kalitatif tahmin metodu insanların kendi tecrübelerine ve sezgilerine dayanarak tahmin yapma yöntemidir. Kantitatif metot ise geçmiş verileri kullanıp, veriler üzerinde sayısal ve istatistiki hesaplamalar yapılarak, verilerin matematiksel modellerle desteklendiği tahmin yöntemidir. Kantitatif bir yaklaşım olan Yapay Sinir Ağları (YSA) ile tahmin modeli, öğrenme ve tecrübe etme yoluyla geçmişte depolanan bilgilerden kararların nasıl alınabileceğini yani bilgisayarlarda işlenmiş bilgilerin nasıl elde edilebileceğini anlamaya çalışan yapay zekâ tabanlı bir tahmin yöntemidir. Bu çalışmada stok yönetimini etkin bir şekilde gerçekleştirmek amacıyla iş makineleri yedek parçaları üreten bir üretim tesisinde YSA kullanılarak talep tahmini uygulaması yapılmış ve ileriye dönük müşteri talepleri ortaya çıkarılmıştır. Geliştirilen modelde geçmiş yıllara ait satış miktarları, dünyada satılan iş makinası sayısı, yıllara ve aylara göre dolar kuru değişimi ve aylık etki oranı değişkenleri yer almaktadır. Uygulamada son 9 yıla ait veriler kullanılmıştır. Gelecek yıl için talep tahminleri geliştirilen YSA modeli ile yapılmıştır. Ayrıca çoklu regresyon analizi ile de talep tahmini yapılmış olup sonuçlar karşılaştırılmıştır. Yapay sinir ağlarının tahmin yapmada daha iyi sonuçlar verdiği gözlenmiştir.

**Anahtar Kelimeler:** Talep Tahmini, İş Makineleri Sektörü, Yapay Sinir Ağları, Çok Değişkenli Regresyon

## ABSTRACT

### APPLICATION OF DEMAND FORECASTING WITH ARTIFICIAL NEURAL NETWORKS IN CONSTRUCTION MACHINERY SECTOR

YANIK, Emre

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Industrial Engineering, M. Sc. Thesis

Supervisor: Asst. Prof. Dr. Adnan AKTEPE

June 2019, 100 pages

Demand forecasting methods are classified under two main categories as qualitative and quantitative. The qualitative forecast is a method based on people's personal experience and intuition. The quantitative forecast is a method of using historical data supported by mathematical models and indicating numerical and statistical calculations on the data. Forecasting with Artificial Neural Networks (ANN) is an artificial intelligence-based method that indicates how decisions can be made from information stored in the past through learning and experience. In this study, demand forecasting application was performed by using ANN in a production facility that produces spare parts of construction machines. The aim of the study is forecasting demands as close as possible to future customer demands. In the developed model, sales quantities of past years, number of construction machines sold in the world, dollar exchange rate effect according to years and months and monthly effect rate are used as variables. Data for the last 9 years were used in the application. Demand forecasts were realized for the next year with the ANN model. In addition, demand forecasting was performed by multiple regression analysis with the same data and the results were compared. It was observed that ANN give better results.

**Keywords:** Demand Forecasting, Construction Machinery Sector, Artificial Neural Networks, Multivariate Regression.

## TEŞEKKÜR

Yüksek lisans tezi olarak hazırladığım bu çalışmada, rehberliğini ve desteğini esirgemeyen tez danışmanım ve değerli hocam Dr. Öğr. Üyesi Adnan AKTEPE' ye, teze ve yüksek lisans öğrenimime yardımlarıyla ve görüşleriyle büyük katkısı olan değerli hocam Prof. Dr. Süleyman ERSÖZ'e

Biz genç mühendislere şans vererek kapılarını açan, iş ve hayat tecrübesi kazanmamız noktasında bize yardımcı olan, bizleri dinleyen ve değer veren değerli yöneticim Sadık ÖNER'e

Bugünlere gelmemde bana en büyük desteği veren ve yüksek lisans çalışmamı bitirmemi çok isteyip beni teşvik eden canım anneme ve babama teşekkür ederim.

Haziran 2019

Emre YANIK

(Endüstri Mühendisi)

# İÇİNDEKİLER DİZİNİ

Sayfa

<b>ÖZET</b> .....	<b>i</b>
<b>ABSTRACT</b> .....	<b>ii</b>
<b>TEŞEKKÜR</b> .....	<b>iii</b>
<b>İÇİNDEKİLER DİZİNİ</b> .....	<b>iv</b>
<b>ÇİZELGELER DİZİNİ</b> .....	<b>vii</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>viii</b>
<b>KISALTMALAR DİZİNİ</b> .....	<b>x</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. LİTERATÜR ARAŞTIRMASI</b> .....	<b>4</b>
<b>3. TALEP TAHMİNİ</b> .....	<b>9</b>
3.1. Talep Tahmin Kavramı .....	9
3.2. Tahmin İhtiyacı .....	9
3.3. Üretim Planlaması Ve Kontrolünde Talep Tahmininin Önemi.....	11
3.4. Stok Yönetiminde Talep Tahmininin Önemi .....	13
3.5. Talep Tahmininin Aşamaları.....	15
3.6. Talep Tahmin Yöntemleri .....	16
3.6.1. Nitel Tahmin Yöntemleri.....	17
3.6.2. Nicel Tahmin Yöntemleri .....	19
3.7. Tahmin Yöntemlerinin Doğruluğunun Ölçülmesi .....	38
3.7.1. Ortalama Hata (ME) .....	39
3.7.2. Ortalama Mutlak Hata (MAE).....	39

3.7.3. Ortalama Hata Karesi (MSE).....	39
3.7.4. Ortalama Mutlak Hata Yüzdesi (MAPE).....	40
<b>4. YAPAY SİNİR AĞLARI.....</b>	<b>41</b>
4.1. Yapay Zekâ Bilimi .....	41
4.2. Yapay Sinir Ağlarının Genel Tanımı .....	43
4.3. Yapay Sinir Ağı Tanımı ve Görevi .....	43
4.4. Yapay Sinir Ağlarının Genel Özellikleri.....	45
4.4. Yapay Sinir Ağlarının Dezavantajları .....	46
4.5. Yapay Sinir Ağlarıyla Neler Yapılabilir .....	47
4.6. Yapay Sinir Ağlarının Tarihçesi.....	50
4.6.1. Başlangıç Çalışmaları .....	51
4.6.2. Altın Çağ.....	51
4.6.3. Uzun Sessizlik Ve Yeniden Yapılanma.....	52
4.6.4. Rönesans .....	53
4.7. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları.....	53
4.7.1. Biyolojik Sinir Hücreleri (Nöronlar) .....	53
4.7.2. Yapay Sinir Hücresi.....	55
4.8. Yapay Sinir Ağlarının Sınıflandırılması.....	58
4.8.1. Katman Sayısına Göre Sınıflandırma .....	58
4.8.2. Bağlantı Yapılarına Göre Sınıflandırma .....	60
4.8.3. Öğrenme Stratejilerine Göre Sınıflandırma .....	62
4.9. Yapay Sinir Ağlarının Eğitimi ve Öğrenme Kuralları .....	63
4.9.1. Öğrenme Kuralları .....	63
4.10. Çok Katmanlı Algılayıcılar (ÇKA) .....	66
4.10.1. ÇKA Ağının Öğrenme Kuralı.....	67
4.10.2. ÇKA Ağının Çalışma Prosedürü .....	72
4.10.3. Ağın Öğrenme Yerine Ezberleme Yapması .....	73

<b>5. TALEP TAHMİNİ UYGULAMASI .....</b>	<b>74</b>
5.1. Firma ve Ürün Bilgisi.....	74
5.2. Talep Tahmininin Amacı.....	74
5.3. Talep Tahmin Probleminin Tanımlanması ve Veri Setinin Hazırlanması .....	75
5.4. Tahmin Yönteminin Seçilmesi.....	80
5.5. Yapay Sinir Ağı Mimarisinin Oluşturulması Ve Eğitimi.....	81
5.5.1. Öğrenme Katsayısının Belirlenmesi .....	82
5.5.2. Çevrim Sayısının Belirlenmesi .....	82
5.6. Matlab’da Yazılan Kodlar .....	83
5.6.1. Veri Setinin Matlab’a Okutulması.....	83
5.6.2. Verilerin Normalize Edilmesi .....	84
5.6.3. Sinir Ağının Oluşturulması ve Parametrelerinin Belirlenmesi.....	85
5.6.4. Sinir Ağının Eğitilmesi .....	86
5.6.5. Sinir Ağının Performansının Test Edilmesi.....	86
5.7. YSA Tahmin Sonuçları .....	87
5.8. Çok Değişkenli Regresyon Analizi İle Tahmin Uygulaması .....	90
<b>6. SONUÇ VE DEĞERLENDİRME .....</b>	<b>93</b>
<b>KAYNAKLAR .....</b>	<b>95</b>

# ÇİZELGELER DİZİNİ

<u>ÇİZELGE</u>	<u>Sayfa</u>
3.1. Stok maliyetleri .....	15
4.1. YSA' nın kullanıldığı bazı alanlar .....	50
4.2. Aktivasyon fonksiyonu örnekleri.....	58
4.3. XOR problemi.....	66
5.1. Aylık satış miktarı verileri .....	76
5.2. Dünya yıllık iş makinesi satış adetleri .....	77
5.3. Dünya aylık iş makinesi satış adetleri.....	77
5.4. Aylık dolar kuru verileri.....	78
5.5. Enflasyona göre düzenlenmiş aylık dolar kuru verileri .....	79
5.6. Aylık etki oranı değerleri .....	80
5.7. En iyi YSA mimarisi için deneme yanılma sonuçları.....	83
5.8. YSA tahmin sonuçları .....	87
5.9. Ağ ilerleme verileri .....	89
5.10. Çok değişkenli regresyon ağırlık katsayıları.....	90
5.11. Çok değişkenli regresyon analizi tahmin sonuçları .....	91



# ŞEKİLLER DİZİNİ

<u>ŞEKİL</u>	<u>Sayfa</u>
3.1. Üretim planlama ve kontrol fabrika sinir sistemi.....	12
3.2. Üretim planlama ve kontrolün amaçları.....	13
3.3. Tahmin yöntemleri .....	17
3.4. Farklı desenleri gösteren dört zaman serisi örneği.....	21
3.5. Regresyon doğrusu.....	29
3.6. Farklı korelasyon durumları.....	30
3.7. Box-Jenkins modelleme yaklaşımı.....	33
3.8. İnsan boyu için bulanık yaklaşım.....	37
4.1. Örnek bir yapay sinir ağı.....	45
4.2. İki biyolojik sinir hücresinin bağlantısı.....	54
4.3. Yapay sinir hücresinin yapısı .....	55
4.4. Sigmoid fonksiyonu.....	57
4.5. Çok katmanlı bir yapay sinir ağı örneği.....	60
4.6. İleri ve geri beslemeli ağ yapıları.....	61
4.7. Bir yapay sinir hücresinin(proses elemanı) çalışma örneği .....	68
4.8. Başlangıç ağırlıklarıyla yapılan tahmin .....	69
5.1. Ağ mimarisi.....	81
5.2. Verilerin okutulması ve ayrılması için kodlar.....	84
5.3. Verilerin matris formuna dönüşmesi ve normalizasyonu .....	85
5.4. Sinir ağının oluşturulması .....	85
5.5. Sinir ağının eğitilmesi .....	86
5.6. Ağın performansının ölçülmesi.....	87

5.7. YSA tahmin sonuçlarının gerçekleşen taleplerle karşılaştırılması.....	88
5.8. Performans grafiđi.....	88
5.9. Regresyon grafiđi.....	89
5.10. Çok deđişkenli regresyon tahmin deđerleri ve gerçekleşen deđerler.....	91
5.11. Regresyon analizi model özeti .....	92
5.12. Regresyon analizi anova özeti.....	92



## KISALTMALAR DİZİNİ

- ADALINE** : Adaptif Doğrusal Eleman  
**AR** : Otoregresif  
**ARIMA** : Bütünlesik Otoregresif Hareketli Ortalama  
**ARMA** : Otoregresif Hareketli Ortalama  
**ÇKA** : Çok Katmanlı Algılayıcı  
**MA** : Hareketli Ortalama  
**MADALINE** : Çoklu Adaptif Doğrusal Eleman  
**MAE** : Ortalama Mutlak Hata  
**MAPE** : Ortalama Mutlak Hata Yüzdesi  
**ME** : Ortalama Hata  
**MSE** : Ortalama Hata Karesi  
**ÜPK** : Üretim Planlama ve Kontrol  
**YSA** : Yapay Sinir Ağları  
**YZ** : Yapay Zeka

# 1. GİRİŞ

İş makineleri madencilik, kaldırma, malzeme taşıma, kazı ve tünel açma gibi inşaat işlerinde kullanılan araçlardır. Ekskavatörler, Kazıcı Yükleyiciler, Dozerler ve Greyderler iş makinesi çeşitlerine örnek olarak verilebilir. Dünya üzerinde yapılan, alt yapı, ulaşım, enerji ve kentsel dönüşüm gibi harcamalar artmaya devam ettikçe iş makineleri sektörü de giderek büyümeye devam edecektir.

Dünya inşaat makineleri talebinin, Asya/ Pasifik bölgesi, Orta ve Güney Amerika ile Afrika/ Ortadoğu bölgesinde, özellikle gelişmekte olan ülkeler artmaya devam ettikçe, ortalamanın üstünde artış göstermesi beklenmektedir.

Dünya üzerinde yapılan sayısız inşaat projelerinde sayısız iş makinesi çalışmaktadır. İş makineleri çoğunlukla zorlu arazi koşullarında çalıştıkları için, çeşitli parçalarında zamanla eskime, deformasyon ve kırılma gibi olumsuz durumlar meydana gelmektedir. Bu nedenle iş makinesi parçaları çalışma fonksiyonlarını eskisi gibi yerine getirememektedir. Bu durum yedek parça ihtiyacını ortaya çıkarmaktadır.

İş makineleri üreten firmalar veya sahip oldukları iş makinelerini inşaat şirketlerine veya çeşitli kurumlara kiraya veren firmalar ya da şahıslar, iş makinelerinin yedek parçalarına her an ihtiyaç duymaktadırlar. Yüksek ücretlerle satın alınan ya da günlük, haftalık veya aylık olarak yüksek ücretlerle kiralanan iş makinelerinin, herhangi bir parçasında meydana gelen bir arızadan dolayı çalışmaması, gerek iş makinesini kiraya verenler açısından gerekse kiralayanlar açısından çeşitli mağduriyetlerin olduğu son derece problemlidir.

İş makinelerinin yedek parçalarının temin edilememesi hem yüksek maliyetlere hem de zaman kayıplarına neden olacağından yedek parçaların istenilen zamanlarda bulunabilirliği son derece önemlidir. Bu gibi nedenlerden dolayı, müşteriler ürün gurubunun kompleksine veya ürün gurubu içerisindeki herhangi bir parçaya ihtiyaç duyduklarında gerekli yedek parçaları son derece hızlı bir şekilde temin etmek isterler. Sektörün bütün bu özelliklerinden ötürü iş makinesi parçaları üreten işletmelerin, doğru zamanlarda stok bulundurmaları birlikte ürünlerin üretimini doğru zamanlarda ve en hızlı şekilde gerçekleştirerek müşterilere ulaştırması gerekmektedir. Aksi halde

rekabetin her geçen gün arttığı günümüz dünyasında işletmelerin ayakta kalması mümkün olmayacaktır.

Sanayinin gelişmesiyle birlikte bir iş kolu üzerinde birçok üretici faaliyet gösterebilmektedir. Bu durum müşteriler açısından alternatifler oluşturmaktadır. Müşteriler fazla sayıda ürün almak yerine ihtiyacı kadar ürün almaktadır. Bir başka deyişle müşteriler tedarikçi bolluğunun vermiş olduğu güvenle stok tutmayıp daha sonraki ihtiyaçlarında ürünü kolaylıkla bulabileceğini düşünmekte ve endişe etmemektedir. Müşterilerin stok tutmayı tercih etmemesi, üretim yapan işletmeleri gereksiz stok tutmaları halinde çok zor durumlara sokabilir. Bu nedenle üretici işletmeler stoklarını yönetirken piyasayı ve müşterilerini iyi analiz etmeli, doğru iş tahminleri yaparak rekabet koşullarında varlığını sürdürmelidir.

Tüm kuruluşlar bilinmeyen, belirsiz bir gelecekle uğraştıklarından, gelecekle ilgili kararları alırken tahminler yaparlar. Yapılan tahminlerin ilk aşaması şüphesiz talep tahminleridir. Talep tahminleri, planlama faaliyetlerine girdi olarak kullanılmakta ve temel operasyonların yönetiminde önemli bir rol oynamaktadır. Doğru talep tahmini, birçok kuruluş için önemli bir husustur. Envanter yönetiminin her bölümü için bir temel oluşturur. Talep tahminleri olmadan, işletmeler ürünleri ve hedef pazarları hakkında zayıf kararlar alma riskiyle karşı karşıya kalır ve yanlış alınmış kararların stok tutma maliyetleri, müşteri memnuniyeti, tedarik zinciri yönetimi ve kârlılık üzerine olumsuz etkileri olabilir.

Yapay sinir ağları tahmin yaparken birikmiş verilerden yararlanarak öğrenme yoluyla akıllı kararlar almanın yolunu sunan bir yöntemdir.

Bu çalışmada iş makineleri sektöründe talep tahmini yapay sinir ağları kullanılarak yapılmış ve yapay sinir ağlarının talep tahmininde kullanılabilen başarılı bir yöntem olduğu gösterilmeye çalışılmıştır.

İkinci bölümde, talep tahmini ve yapay sinir ağları ile ilgili literatürde yapılan çalışmalar incelenerek özet şeklinde sunulmuştur.

Üçüncü bölümde, talep tahmini kavramı ve talep tahmini yapılırken kullanılan tahmin yöntemleri ayrıntılı olarak anlatılmış, dördüncü bölümde, yapay sinir ağları yönteminin tanımından, genel özelliklerinden, tarihsel gelişiminden, yapısından ve öğrenme kurallarından bahsedilmiştir.

Beşinci bölümde ise iş makineleri yedek parça sektöründe faaliyet gösteren bir firmanın ERP sisteminde biriken satış verileri toplanarak satışları etkileyen değişkenler belirlenmiş daha sonra yapay sinir ağı yöntemi kullanılarak tahmin işlemi matematiksel olarak modellenmiş ve tahmin uygulaması gerçekleştirilmiştir. Ayrıca çoklu regresyon modeli ile de talep tahmini yapılmış ve yöntemlerin sonuçları karşılaştırılmıştır.



## 2. LİTERATÜR ARAŞTIRMASI

Günümüzde geleceği tahmin edebilmek, gerek şirketler açısından, gerekse ulusal ve uluslararası ekonomiler açısından büyük bir önem kazanmıştır. Veri analiz yöntemleri kullanılarak geliştirilen tahmin uygulamaları bugün ve endüstriyel alanda ve birçok disiplinde geniş bir uygulama alanına sahiptir.

Bu çalışmada daha güncel bilgiler ve uygulamalar göstermek açısından 2001 yılı ve sonrasında yayınlanan çalışmalar incelenmiştir. Literatürde incelenen talep tahmini çalışmaları aşağıda özetlenmiştir:

Ringwood vd. [1], yapmış oldukları çalışmada ekonomik ve çevresel nedenlerden dolayı değişen elektrik enerjisi tüketimini yapay sinir ağları(YSA) ile tahmin ederek, elektrik üretiminin talebe uygun şekilde gerçekleşmesini sağlamışlardır.

Alon vd. [2], perakende sektöründe gerçekleştirdikleri uygulamada, fazla eğilim ve mevsimsellik içeren satış verilerini kullanarak YSA, Winters Üssel Düzeltme, Box-Jenkins ARIMA modeli ve Çok Değişkenli Regresyon gibi yöntemlerle talep tahmini yapmış, sonuçları karşılaştırmışlardır. YSA'nın diğer yöntemlere göre daha başarılı tahminler gerçekleştirdiğini gözlemlemişlerdir.

Frank, Garg vd. [3], kadın hazır giyim satışlarını tahmin etmek için istatistiksel zaman serileri modellemesi ve YSA kullanmışlardır. Oluşturdukları modelde 1997-2000 yılları arasındaki dört yıllık satış verilerini kullanmışlar ve 2000 yılının ikinci ayına ilişkin bir tahmin yapmışlardır. Mevsimsel düzeltme ve Winters üssel düzeltme yöntemine göre YSA ile yapılan tahmin daha iyi bir  $R^2$  değeri vermiştir.

Adıyaman [4], yüksek lisans tezindeki çalışmasında, işçilik değeri düşük altın ürün satışlarını ve işçilik değeri yüksek altın ürün satışlarını yapay sinir ağları kullanarak tahmin etmiştir. Satış verilerini ayar ve gr bazında derleyerek 1997-2005 yılları arasındaki verileri ağı eğitilmesi için, 2006 yılı verilerini ise ağı test edilmesi için kullanmıştır. Ayrıca çoklu regresyon ve eğri uydurma yöntemleriyle de tahmin

çalışması yapmış yöntemlerin başarısını karşılaştırmıştır. YSA'nın diğer yöntemlere göre daha başarılı tahmin yaptığını söylemiştir.

Çuhadar vd. [5], Antalya iline ait aylık dış turizm talebini yaptıkları çalışmada, 1992-2005 yılları arasındaki ziyaret eden yabancı turist sayısı verilerinden yararlanmışlar, üssel düzeltme, Box-Jenkins ve farklı mimarilere sahip YSA modelleri ile tahmin doğruluklarını karşılaştırmışlardır. Çalışmaları sonucunda gerçek değerlere en yakın sonucu veren yöntem YSA olmuştur.

Yazıcıoğlu [6], yaptığı çalışmada, Türkiye'deki Mart 2001- Haziran 2009 arasında aylık bazda üretilen binek otomobil verilerini ve satışı etkileyen verileri toplayarak yapay sinir ağları ve çoklu regresyon analizi ile satış tahmini yapmıştır. İki gizli katmanlı olarak eğittiği YSA modelinin çok daha başarılı bir tahmin sonucu ürettiğini gözlemlemiştir.

Karahan [7], doktora tezinde yaptığı çalışmada, Malatya ili kuru kayısı üretimine ait yurtdışı (ihracat) talep tahmini uygulaması yapmıştır. Dolar kuru, aylık kuru kayısı fiyatı, ihracat yapılan ülke sayısı ve mevsimsel etki gibi değişkenleri kayısı talebine etki eden faktörler olarak belirlemiştir. Çalışmada ileri beslemeli geri yayımlı bir sinir ağı modeli oluşturularak tahmin problemini çözmüştür.

Yücesoy [8], temizlik kağıtları sektöründe yaptığı çalışmada, yıllık temizlik kağıtları satışı ile ilgili YSA ve çok değişkenli regresyon modeli kurmuştur ve tahmin başarılarını karşılaştırmıştır. 1981-2010 yılları arasındaki 29 adet verinin, 24 adedini ağı eğitmek için 5 adedini ise test için kullanmıştır. 7 bağımsız değişken, 1 ara katman ve 3 gizli hücre sayısı ile modellediği ağ mimarisi, basit ve çoklu regresyon yöntemine göre daha etkin bir tahmin başarısı sağlamıştır.

Serttaş [9], yaptığı çalışmada, bir süpermarkette satılan bir ürün için yapay sinir ağları ile talep tahmin uygulaması gerçekleştirmiştir. YSA' da eğittiği en uygun ağ modeli ile parametreleri kaldırarak ayrıca bir tahmin çalışması yapmış ve iki durumu kıyaslamıştır. Çalışma sonucunda ürün satışlarının özel günlerde fazlaca değiştiğini gözlemlemiş ve perakende sektörünün toplumdaki ekonomik yaşamdan daha fazla toplumdaki psikolojik hareketlilikten etkilendiği yorumunu yapmıştır.

Aktepe vd. [10], san-tez projelerinde, makine kimya fabrikasında üretilen topçu mühimmatı kaynak prosesini yapay sinir ağı kullanarak iyileştirmişler ve hatalı ürün



oranını azaltmışlardır. Modelde 22 adet girdi değişkeni ve 3 adet çıktı değişkeni kullanmışlardır. Kaliteli bir kaynak işleme için bu girdi değişkenlerinin optimum değerlerini bulmuşlardır.

Kaynar vd. [11] , yapmış oldukları çalışmada, Ankara iline ilişkin Ocak 2005 ile Haziran 2006 arasındaki günlük ve haftalık doğalgaz arz değerlerini kullanarak çok katmanlı yapay sinir ağı modeli ve ARIMA modeli ile modelleyerek doğalgaz talebine ilişkin kısa süreli bir tahmin yapmışlardır. YSA'nın ARIMA modeline göre daha iyi sonuçlar verdiğini gözlemlemiş, yapılan talep tahminlerinin sektöre yapılacak yatırımlarda ve gaz alımı ile ilgili anlaşmalarda kullanılabileceğini söylemişlerdir.

Sevgi [12], yaptığı çalışmada, hazır giyim perakendeciliği yapan bir firmanın 6 yıllık haftalık satış verilerini kullanmış, dinamik bir yapay sinir ağı modeli olan NARX (Nonlinear autoregressive exogenous model) modelini kurarak tahmin uygulaması gerçekleştirmiştir. Ayrıca ARIMA modeli ile de tahmin yaparak sonuçları karşılaştırmıştır. NARX modelinin eğitim, sağlama ve test sonucunda daha az hata oranı verdiğini gözlemlemiştir.

Boltürk [13], yaptığı çalışmada, bir şirketin 12 yıllık elektrik tüketim verilerini aylık bazda toplamıştır. 2000-2012 yılları arasında topladığı elektrik tüketim verilerini üç senaryo oluşturarak tahmin etmede kullanmıştır. Birinci senaryoda 2011 yılı verilerinden 2012 yılını tahmin etmiş, ikinci senaryoda 2009, 2010 ve 2011 yıllarındaki 3 yıllık verilerden 2012 yılı tüketim verilerini tahmin etmiş, üçüncü senaryoda ise 2000-2011 yılları arasındaki verilerin tümünü kullanarak 2012 yılını tahmin etmiştir. Senaryolar için ayrı ayrı tahminler yaparken tahmin yöntemi olarak, Hareketli ortalama, Holt Modeli, Üssel Düzeltme Modeli, Basit ve Çoklu Regresyon, Bulanık Mantık, ARIMA ve YSA modelleri gibi metotlar kullanmıştır. Sonuç olarak kısa dönemli elektrik tüketim talep tahmininde Bulanık Mantık en iyi sonucu verirken, Holt modeli, Hareketli Ortalama ve YSA, orta dönemli elektrik tüketim tahmininde başarılı olmuştur. Uzun dönemli tüketim talebini tahmin etmede ise Üssel Düzeltme ve Çoklu Regresyon Modelleri başarılı olmuştur.

Ballı [14], yaptığı çalışmada, hızlı tüketilen taze gıda sektöründe, şarküteri gurubu ürünleri için yapay sinir ağı modeli kullanarak talep tahmini uygulaması yapmıştır.

Ayrıca ortalama bazlı zaman serisi analiz yöntemleri ile de tahminler yapmış sonuçları karşılaştırmıştır.

Es vd. [15] , yaptıkları çalışmada, 1970-2010 yılları arasındaki değişken değişken verilerini kullanarak oluşturdukları tek ara katmanlı ileri beslemeli geri yayımlı YSA modeli ile Türkiye net enerji talebini 2011-2025 yılları için tahmin etmişlerdir. Çoklu regresyon ile de tahmin yapılmış, YSA modelinin tahmin performansının daha üstün olduğunu gözlemlemişlerdir.

Özüdoğru ve Görener [16], bir hastane kurumunda kullanılan temel medikal malzemelerin 2010-2014 yıllarındaki gerçek talep verilerini kullanarak, hareketli ortalama, tek üssel düzeltme, Holt Winters yöntemleri ve doğrusal regresyon yöntemi ile 2015 yılındaki talebi aylık olarak tahmin etmişlerdir.

Sarı [17] , yapmış olduğu çalışmada, dolar kuru, Gayri Safi Yurtiçi Hasıla (GSYH), araç parkı sayısı, üretilen araç sayısı, ihracat sayısı, faiz oranı, Tüfe ve Üfe gibi etkenleri, motor yataklarının satışını etkileyen faktörler olarak belirlemiş ve bu değişkenlerle ilgili verileri toplayarak, YSA, çoklu regresyon yöntemi ve zaman serileri analiz yöntemleriyle talep tahmini çalışması yapmıştır. YSA tekniğinin daha başarılı olduğunu gözlemlemiştir.

Silva vd. [18] , yapmış oldukları çalışmada, gelen siparişleri karşılamak ve bir sonraki siparişin hangi tedarik zinciri düğümünde olacağını tahmin etmek için simüle edilmiş bir tedarik zinciri modeli geliştirmişler ve simülasyon çalışmasında ürettikleri verileri YSA için girdi olarak kullanmışlardır. Tek gizli katmanlı olarak oluşturdukları çok katmanlı YSA modeliyle 2 deney yapmışlardır. 1. deneyde yaklaşmakta olan siparişleri anında gönderme kapasitesini tahmin ederken, 2. deneyde yeniden sipariş noktasının tedarik zincirinin hangi düğümünde olacağını tahmin etmişlerdir. Böylelikle YSA kullanarak tedarik zincirinde görünürlüğü artırmayı hedeflemişlerdir.

Merkuryeva vd. [19] , ilaç tedarik zincirinde yapmış oldukları çalışmada, bir toptancıdan gelişmekte olan bir pazarda bulunan dağıtım şirketine, tıbbi ürünler için entegre bir prosedür sunmuşlardır. Basit hareketli ortalama yöntemini kullanarak temel talep hesaplamaları için alternatif tahmin senaryoları geliştirmişler ve bu senaryoları çoklu doğrusal regresyon yöntemi ve sembolik regresyon yöntemi ile

tahminler yapmışlardır. Gerçeğe en yakın ve en uygun tahmin yönteminin sembolik regresyon olduğunu göstermişlerdir.

Türk ve Kiani [20] , yaptıkları çalışmada, 2007 yılından 2015 yılına kadar olan beyaz eşya satışına ait verileri kullanarak tek gizli katmanlı ileri beslemeli geri yayımlı YSA modeli ile Türkiye’deki toplam beyaz eşya satışlarını tahmin etmişlerdir. Ayrıca çok değişkenli regresyon analizi ile de tahmin yapmışlar fakat YSA’nın daha iyi sonuç verdiğini gözlemlemişlerdir.

Literatürde araştırılıp incelenen çalışmalarda genel olarak YSA’nın tahmin yapmada başarılı bir yöntem olduğu görülmüştür. Talebi etkileyen bağımsız değişkenler ve talep verilerinin düzgün olarak toplanması halinde, yapay sinir ağlarının ilişkileri keşfetmede diğer geleneksel yöntemlere göre daha üstün bir yöntem olduğu çoğu çalışmada ispatlanmıştır.

## 3. TALEP TAHMİNİ

### 3.1. Talep Tahmin Kavramı

Talep, tüketicilerin belirli bir süre içerisinde satın almaya istekli ve satın alabilecekleri bir ürün veya hizmetin miktarı olarak tanımlanabilir. Talep tahmini ise gelecekte veya yakın bir zamanda ortaya çıkabilecek talep seviyesini tahmin etme sanatıdır [21] .

Şirketlerin rekabetçi olabilmesi için, maliyetleri kontrol altında tutarken, yüksek müşteri hizmetleri seviyelerine çıkmaları gerekir. Şirketler bunu müşterilerin talebini tahmin ederek ve planlayarak yönetir. Eğer şirket müşteri talebini planlamada başarılı olmazsa, ya satış fırsatlarını kaçıır ya da satılmayan ürünlerin stoklanmasından dolayı stok maliyetlerini artırır [22] .

Talep tahminleri, planlama faaliyetlerine girdi olarak kullanılmakta ve temel operasyonların yönetiminde önemli bir rol oynamaktadır. Doğru talep tahmini, birçok kuruluş için önemli bir husustur. Envanter yönetiminin her bölümü için bir temel oluşturur. Talep tahminleri olmadan, işletmeler ürünleri ve hedef pazarları hakkında zayıf kararlar alma riskiyle karşı karşıya kalır ve yanlış alınmış kararların stok tutma maliyetleri, müşteri memnuniyeti, tedarik zinciri yönetimi ve kârlılık üzerine olumsuz etkileri olabilir. İyi bir talep tahmini için, öncelikle talebi etkileyen faktörlerin belirlenmesi gerekmektedir.

### 3.2. Tahmin İhtiyacı

Yönetimler karar vermek için tahminler yaparlar. İş tahmini, satışlar, harcamalar ve kârlar gibi gelecekteki gelişmelerin tahminidir. Tahminler, ekonomideki dalgalanmalar ve bu dalgalanmaların kâr marjları üzerindeki ciddi etkileri göz önüne alındığında, iş planlamasının ve kurumsal planlamanın en önemli yönlerinden biri olarak ortaya çıkmaktadır. Tahmin, yöneticilerin ekonomik trendleri tahmin etmeleri ve bunlardan faydalanmaları veya bunlarla mücadele ederek kendilerini hazırlamaları için paha biçilmez bir araç haline gelmiştir. Örneğin, yöneticiler ekonomik bir

gerileme öngörülürse, stoklarını, üretim kotalarını ve işe alımlarını azaltabilirler. Aksine, ekonomik bir patlama muhtemel görünüyorsa, aynı yöneticiler bundan maksimum faydayı elde etmek için gerekli önlemleri alabilirler. İyi iş tahminleri, işletme sahiplerinin ve yöneticilerinin değişen ekonomiye uyum sağlamalarına yardımcı olabilir.

İş tahminlerinin önemli avantajlarından bazıları aşağıda anlatılmıştır [23] :

**Üretim planlamasında yardımcı olur:** Ürünlerin üretilme oranı gelecek zamanlarda dalgalanabilecek talep ile eşleştirilmelidir. Üretim yöneticisinin, üretim kapasitesini değişen aylık talepleri karşılayacak şekilde düzenleyebilmesi için talep tahminlerine ihtiyacı vardır.

**Finansal planlamaya yardımcı olur:** Satış tahminleri bütçe planlarının yapılmasında çok önemlidir. Satış tahminleri malzeme alımı, işçilik ücretleri vb. giderleri karşılamak ve işletmeye nakit giriş çıkışlarının zamanlamasını ayarlamak için çok önemli bir girdidir. İyi yapılan satış tahminleri finansal planlamaya büyük katkılar sağlayabilir.

**İşgücü planlamasında yardımcı olur:** İşletmeler belirli bir zaman dilimi içerisindeki talebi karşılayabilmeleri için işgücü değişiklikleri yapabilirler. Örneğin yıllık talebin tahmini aylık taleplere bölünerek işgücünün aylık talebi karşılayacak şekilde ayarlanması gerekebilir.

**Karar vermede yardımcı olur:** Tahminin amacı karar vermek için bilgi sağlayarak gelecekteki belirsizlikleri ortadan kaldırmaktır. Yöneticiler kâr edebilmek için tahminlerde bulunurlar. İş dünyasında tahmin her aşamada yapılabilir. Bir yönetici istatistiklerden ya da istatistiksel tahmin teorilerinden hoşlanmayabilir, ancak tahminlerde bulunmadan adım atamaz. Üretim, satış ve yatırım iş planları, ürüne yönelik talep, ürünün satış fiyatı gibi bilgilerin hepsi belirli öngörüler gerektirmektedir. Tahminlerin içerisinde talep tahmini en önemlisidir. Bir şirketin çeşitli bölümlerinin bütçeleri, beklenen satışlara dayanarak oluşturulur. Verimli üretim programları ile işletme maliyetlerinin minimuma indirilmesi ve kâr getirecek varlıklara yatırım yapılması doğru talep tahminleriyle mümkün olabilir.

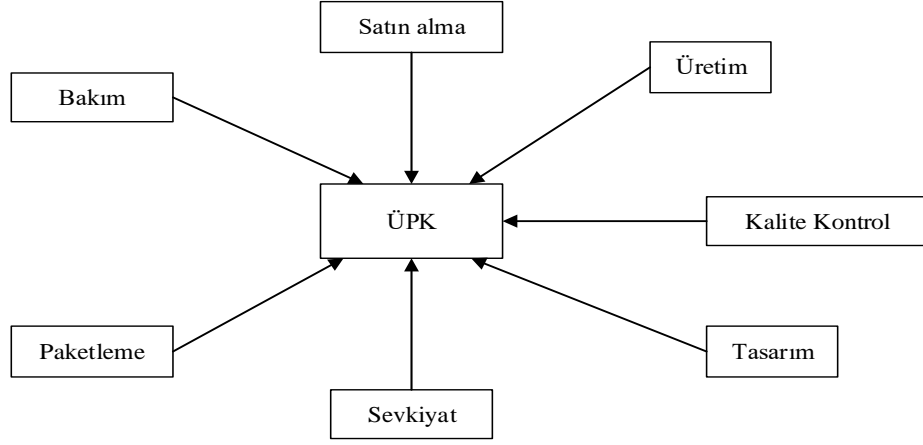
### 3.3. Üretim Planlaması Ve Kontrolünde Talep Tahmininin Önemi

Üretim, işçi, malzeme, sermaye, bilgi ve enerji gibi bir dizi girdiyi bitmiş ürünler ve hizmetler gibi belirli bir çıktı setine uygun miktarda ve kalitede dönüştürmek için geliştirilmiş bir işlem veya prosedürdür. Müşteriye kaliteli ve işlevine uygun olan kabul edilebilir bir ürün üretmek için sıralı işlemler dizisinden oluşur.

Üretimi iyi bir şekilde yönetebilmek için planlama ve kontrol iki önemli unsurdur. Üretim Planlama ve Kontrol (ÜPK) bir üretim sistemindeki tüm üretim faaliyetlerini kontrol eden bir iştir. Üretim planlaması verilen bilgilerin analizi ile başlar (ürünlere olan talep, teslimat programı, müşteri bilgileri vb.) ve mevcut bilgilere dayanarak firmanın makina, işçilik ve malzeme gibi kaynaklarını etkin, verimli ve ekonomik bir şekilde kullanmaya çalışır. Plan hazırlandıktan sonra, işlemler planda verilen detaylar doğrultusunda gerçekleştirilir. Planlanan ile gerçekleşen süreçler arasında herhangi bir sapma olursa üretim kontrolü devreye girmekte ve kontrol teknikleri kullanılarak plandaki hedeflere ulaşmak için düzeltici eylemler gerçekleştirilmektedir.

Charles A. Koepke üretim planlama ve kontrol sürecini “işletme tesislerini ekonomik olarak kullanarak tüm üretim süreci boyunca gerekli malzemelerin tedarik edilmesinden bitmiş malların sevkiyatına kadar önceden belirlenmiş bir hızda gönderilmesi için sistem elemanlarının hareketlerini düzenleyen bir dizi fonksiyonun koordinasyonu” olarak tanımlanmaktadır.

Üretim planlama ve kontrol aslında bir düzenleme yöntemidir. Hammadde üretiminden nihai ürün teslimine kadar ürün hareketini tüm üretim döngüsüne yönlendirerek maksimum üretim, asgari stok ve hızlı teslimatla müşteri memnuniyetinin kazanılması gibi hedefleri gerçekleştirilmektedir. Şüphesiz bu hedefleri gerçekleştirmek için müşteri taleplerinin çok iyi tahmin edilmesi ve planların bu tahminler doğrultusunda yapılması şarttır.

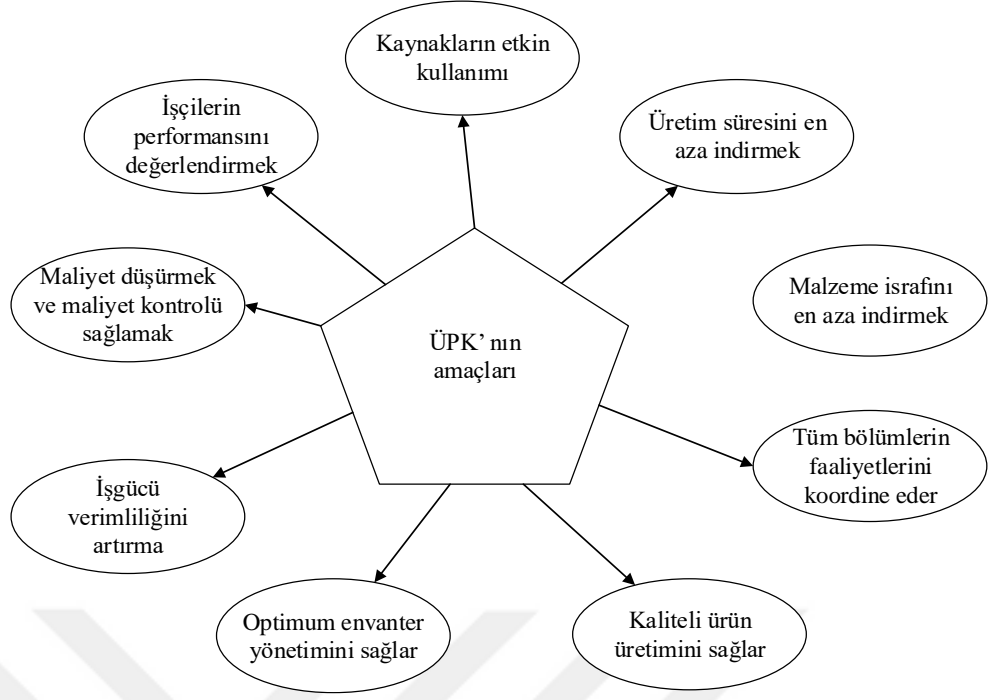


**Şekil 3.1.** Üretim planlama ve kontrol fabrika sınır sistemi [24]

Franklin G. Moore üretim planlama ve kontrolünü insan vücudundaki sinir sistemine benzetmiş, sinir sisteminin insan vücudundaki kas hareketlerini düzenlediği gibi aynı şekilde ÜPK'nın da tesisin tüm faaliyetlerini koordine ettiğini söylemiştir.

Üretim planlama ve kontrolünün hedefleri genel olarak aşağıdaki gibidir [24] :

- ✓ Maksimum müşteri memnuniyetini elde etmek için gerekli teslimat çizelgesini hazırlayarak istenilen miktarlarda kaliteli malları müşteriye teslim edilmesini sağlamak.
- ✓ Kaynakların / malzemelerin optimum kullanımını sağlamak.
- ✓ Üretim / üretim döngüsü süresini en aza indirmek.
- ✓ Optimum stok seviyelerini muhafaza etmek.
- ✓ Düzenli, istikrarlı ve dengeli üretim akışı sağlamak için üretim birbiriyle ilgili ya da farklı bölümlerin faaliyetlerini koordine etmek.
- ✓ Ürünlerin teslimat sürelerine yetişmesini sağlamak.
- ✓ Kaliteli ürünlerin üretimini sağlamak.
- ✓ Üretimi darboğazlardan kurtarmak.
- ✓ Maliyetleri azaltmak ve sürekli maliyet kontrolü sağlamak.



Şekil 3.2. Üretim planlama ve kontrolün amaçları [24]

### 3.4. Stok Yönetiminde Talep Tahmininin Önemi

Stok, bir şirketin hammaddelerini, işlenmekte olan ürünlerini (yarı mamüllerini), ürünlerinde kullanılan sarf malzemeleri ve mamul haline gelmiş ürünleri içermektedir.

Stokların kontrolü ve yeterli miktarda korunması, neredeyse tüm işletmeler tarafından yaşanan hayati bir sorundur. Stokları doğru yönetmek çok önemlidir çünkü tüm organizasyonlar günlük olarak stoklarla ilgilenmektedir. Stokların herhangi bir kuruluştaki önemini göz ardı etmek şirketlerin kapanmasına yol açabilir. Müşterilerin ihtiyaçlarını veya isteklerini karşılamak için üretim faktörleri iyi yönetilmezse, şirketler durma noktasına gelecektir. Stok müşteriler tarafından istendiğinde yeterli ürün bulundurulmasından ibarettir ancak işletmeler için stok tutmak bu kadar basit olmamaktadır. Stoklar hem yer kaplayarak imalatı gereksiz yere meşgul etmesi hem de yüksek maliyetlerinden dolayı işletmeler için büyük bir külfettir.



Bilimsel stok kontrolünün ana amacı; hammadde, malzeme, yedek parça ve diğer gereksinim maddelerinden işletmede ne eksik, ne fazla, ancak yeter miktarda hazır bulundurarak üretimin aksatılmadan yürütülmesidir [25] .

Bunun yanı sıra stok hareketlerinin sürekli olarak izlenmesi, gerekli istatistiklerin tutulması, birikmiş satış verilerinden müşterilerin satın alma eğilimlerinin ve satın aldıkları ürünleri hangi zamanlarda satın aldıklarının analiz edilmesi stok kontrolünün amaçlarındandır.

Stokların gereğinden fazla tutulması işletmeler açısından büyük riskler oluşturmaktadır. Çünkü bu durumda işletmeler elindeki sermayesini stoklara yatırmış olacaktır. Stoklar her ne kadar işletmenin malı gibi gözüke de satılmadığı sürece hiç bir getirisi yoktur. Bir üretim işletmesi için gereğinden fazla tedarik edilmiş hammaddeler, makineleri ve çalışanları boş yere meşgul ederek alım maliyetlerinin yanı sıra ekstra maliyetler oluştururlar.

Günümüz rekabet ortamında işletmeler zamanla yarışmaktadır, gereğinden fazla alınmış malzemeleri işlemek yerine acil işlenmesi ve müşteriye ulaştırılması gereken ürünleri işlemek, hem mevcut stokları paraya çevirmek hem de müşteri memnuniyetini sağlamak açısından çok daha doğru olacaktır. Yine gereğinden az tutulan stoklar da işletmeler için sorun teşkil etmektedir. Tedarik edilmesi gereken malzemelerin belirli bir tedarik süresi vardır. İşletmeler tedarikçilerine sipariş verdiklerinde bu süreyi beklemek zorundadır. Ayrıca beklenen bu süreden sonra malzemelerin işleme ulaşmasıyla birlikte imalatta görmesi gereken çeşitli işlemleri vardır. Örneğin, makine işlem süreleri çok yüksek olabilmektedir. Bu gibi nedenlerden dolayı az stok tutmak tekrar tekrar sipariş maliyetlerine, bekleme zamanlarına, tezgâh hazırlık ve işleme maliyetlerine ve işçilik maliyetlerine neden olmaktadır. Bütün bunlar müşteri memnuniyetsizliğinden başlayıp müşteri kaybına kadar giden bir süreci doğurabilir. İşte bütün bu nedenlerle tüm işletmeler için hangi ürünlerden, hangi zamanlarda ve ne miktarda stok tutmaları gerektiği sorusunun cevabını bilmek büyük bir avantaj olacaktır. Bazı stok maliyetleri Çizelge 3.1.'de gösterilmiştir.

### Çizilge 3.1. Stok maliyetleri [26]

Miktara bağlı alım maliyetleri	Müşterinin kaçırılması maliyeti
Hazırlık maliyetleri	Yıpranma ve eskime maliyetleri
Direkt malzeme maliyetleri	Vergiler ve faiz masrafları
Direkt işçilik maliyeti	Depolama maliyetleri
Fazla mesai veya vardiya maliyetleri	Taşıma maliyetleri
Yeni işçi alma, eğitime ve işten çıkarma maliyetleri	Fiyat değişiklikleri
Aşkın kapasite maliyetleri	

### 3.5. Talep Tahmininin Aşamaları

Talep tahmini başlıca altı aşamada gerçekleştirilen bir faaliyettir. Bu aşamalar ve açıklamaları aşağıda verilmiştir:

*1. Talep Tahmininin Amacının Belirlenmesi:* Talep tahmin sürecinin ilk ve en önemli adımudur. Bir işletme tahmin çalışmasına başlamadan önce talep tahmininin amacını açıkça ortaya koymalıdır. Tahmin çalışması yapılacak tahminin amacına göre şekilleneceğinden tahminin hangi ürüne ya da ürün gurubuna yapılacağı, kısa ya da uzun vadeli olması, pazarın tamamına veya bir bölümüne yapılacak olması gibi tüm detayların bu amaca göre belirlenmesi gerekmektedir.

*2. Talep Tahmin Döneminin Belirlenmesi:* Talep tahmini kısa bir süre için ya da uzun bir süre için olabilir. Kısa süreli tahminler yapılırken talebi etkileyen birçok belirleyicinin sabit kalacağı ya da talebe önemli bir şekilde etki etmeyeceği düşünülebilir. Uzun vadede yapılan tahminler için belirleyiciler önemli ölçüde değişebilir. Bu nedenle tahminin yapılacağı zaman aralığını belirlemek önemlidir.

*3. Talebi Etkileyen Faktörlerin Belirlenmesi:* Müşterilerin gelecekteki talep eğilimleri, piyasa durumu, mevsimsel şartlar, ürünün fiyatı, pazardaki alternatif sayısı (rakip firma sayısı) gibi birçok faktörden etkilenebilir. Tahmin yapılmadan önce ürün satışına doğrudan etki edecek bu gibi faktörlerin belirlenerek açıklanması doğru sonuçlar alabilmek için şarttır.

*4. Verilerin Toplanması:* Bu aşamada tahmin için ve talebi etkileyecek faktörler için gerekli veriler toplanır, analiz edilir ve kontrol edilir. Veriler, istatistiksel veya

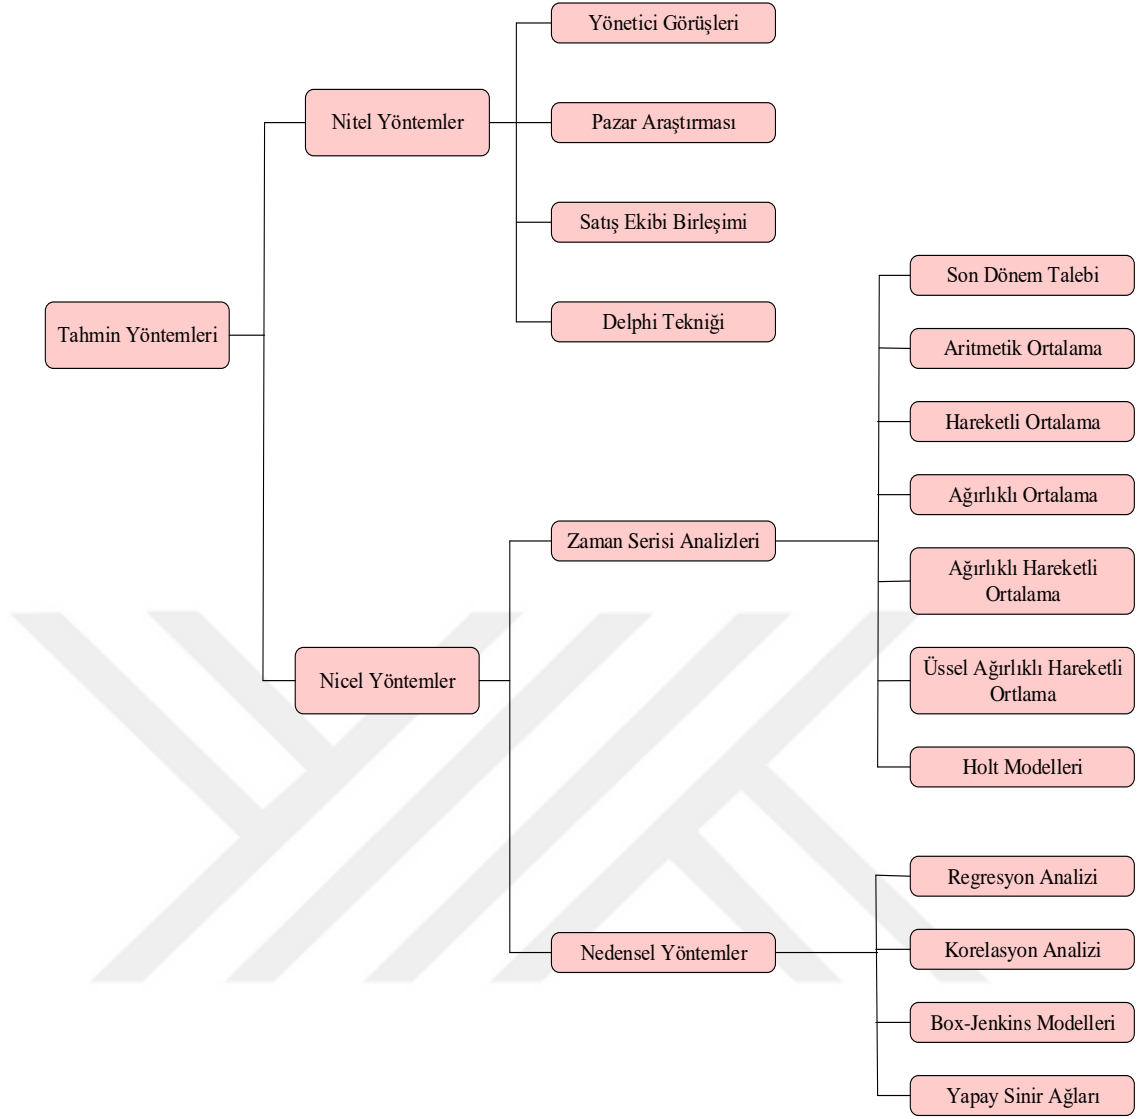
grafiksel teknikler uygulanarak yorumlanır. Eksik ya da hatalı veriler tahmin sonucunu olumsuz etkileyeceğinden verileri toplarken özen göstermek gerekir.

*5. Tahmin Yönteminin Seçilmesi ve Talebin Tahmin Edilmesi:* Tahmin yöntemi seçilirken veri tipi, veri büyüklüğü ve talebin tahmin edileceği zaman aralığı bir çerçevede değerlendirilerek en uygun tahmin yöntemi seçilmelidir. Talep tahmini yöntemi olarak nicel ve nitel yöntemler kullanılabilir. Nicel yöntemler istatistiksel ve matematiksel verilere dayanan yöntemlerdir. Nitel yöntemler ise matematiksel verilerden daha çok tecrübenin uygulanmasına, yargılama ve zekâya dayanan yöntemlerdir [27] .

*6. Tahmin Sonuçlarının Geçerliliğinin Araştırılması:* Yapılan tahmin sonucunda alınan çıktılarla gerçek verilerin karşılaştırıldığı ve hata oranlarının tespit edildiği aşamadır. Tahmin değerleri istenilen düzeyde değilse, toplanan veriler ve yöntem yeniden değerlendirilmeli ve uygunluk dereceleri araştırılmalıdır.

### **3.6. Talep Tahmin Yöntemleri**

Tüketici davranışları üretilen mal veya hizmete göre değişiklik göstereceğinden talebi etkileyecek faktörler çeşitlilik gösterebilir. Talebi etkileyecek faktörlerin artmasıyla yapılan tahminlerin hassasiyeti de artmış ve günümüzde birçok tahmin yöntemi geliştirilmiştir. Talep yöntemleri genel olarak Nitel ve Nicel Tahmin Yöntemleri olarak ikiye ayrılmaktadır. Talep tahmin yöntemleri Şekil 3.3'te gösterilmiştir.



**Şekil 3.3.** Tahmin yöntemleri

### 3.6.1. Nitel Tahmin Yöntemleri

Bu tür tahmin yöntemleri yargılara dayanmaktadır. Görüşler, sezgiler, duygular veya kişisel deneyimlerle tahminler yapıldığından dolayı tabiatı gereği öznelidir. Zorlu matematiksel hesaplamalara dayanmazlar.

### **3.6.1.1. Yönetici Görüşleri**

Gelecekteki satışları tahmin etmek için farklı bölümlerden üst düzey yöneticilerin görüşleri dikkate alınır. Bu tahmin yöntemi, ayrıntılı istatistikler gerekmeksizin kolay ve hızlı bir şekilde yapılabilir. Ancak yöntem bireysel görüşlere dayandığı için en büyük dezavantajı yanlış tahminlere gebe olmasıdır. Burada sorumluluk, kararı birlikte veren yöneticilerin olacaktır.

### **3.6.1.2. Pazar Araştırması**

Pazar araştırması mevcut veya potansiyel müşterilere danışmayı içermektedir. Şirketler, belirli bir ürün ve hizmet pazarının büyüklüğü, kapsamı, demografik özellikleri ve satın alma alışkanlıkları hakkında doğru tahminler yapmak için pazar araştırması yaparlar. Pazar araştırması, tüketici anketlerinden birebir görüşmelere ve öznel ya da nitel bilgi sağlayan panellere kadar uzanmaktadır. Birçok şirket ürün satışlarını kestirebilmek için birincil araştırma aracı olarak pazar araştırmasını kullanmaktadır.

### **3.6.1.3. Satış Ekibi Birleşimi**

Bu yöntemde tahmin, müşterileri ile sürekli etkileşime giren satışçıların görüşlerine dayanarak yapılır. Satışçılar müşterilere çok yakın olduklarından, müşterilerin gelecekteki pazar için gereksinimlerini daha iyi tahmin edebilirler. Her satış elemanı kendi bölgesindeki ya da kendi müşterilerindeki ihtiyaçları bilir, hangi satışların olacağını tahmin eder. Bu tahmin yönteminin temel avantajı, kullanımı ve anlaması çok basit olmasıdır. Bilgi kolayca farklı kategorilere ayrılabilir. Ancak dezavantajı, satış görevlilerinin tahminlerinde ya iyimser ya da karamsar olabilmeleridir bu da yanlış tahminlere neden olabilir

#### **3.6.1.4. Delphi Tekniđi**

Delphi tekniđi, bir ürüne ait gelecekte oluşması beklenen talebin tahmin edilmesi amacıyla, uzman kişilerin yüz yüze görüşmeler ve bir arada tartışmalar yapmadan talebin gelecekte ne olacağı hakkında karar vermelerine ve uzlaşmalarına imkân sağlayan bir yöntemdir [28] .

Delphi tekniđi, 1950'lerde Rand Corporation firmasında geleneksel grup toplantılarının dezavantajlarından kaçınarak, çeşitli uzmanların bilgisinin toplanmasına yardımcı olmak için geliştirilmiştir. Delphi ile tahminde bulunmak için, yöneticiler beş ila yirmi arasında uzmandan konu ile ilgili tahminlerini ve açıklamalarını alırlar. Yönetici daha sonra uzmanlara yapmış oldukları tahminleri ve sebeplerini özet halinde isimsiz olarak tekrar sunar. Uzmanlar diğer görüşleri de değerlendirerek eklemek istedikleri fikirlerini eklerler. İşlem bu şekilde tahminlerde çok az deđişiklik oluncaya kadar birkaç tur devam etmektedir. İki veya üç tur genellikle yeterlidir. Delphi gruplarından gelen tahminler, geleneksel gruplardan gelen tahminlerden önemli ölçüde daha doğrudur [29] .

#### **3.6.2. Nicel Tahmin Yöntemleri**

Nicel yöntemler, geçmiş dönem gözlem deđerlerine dayalı analizler yapan tahmin modellerini kapsamaktadır. Kullanılan yöntemler; incelenen deđişkende gözlenen gelişmelerin analiz edilmesi, veri serisinin dinamik özelliklerinin belirlenmesi ve bu özelliklerin matematiksel bir fonksiyon ile ifade edilerek geleceđe ilişkin öngörülerin türetilmesini içermektedir [6] .

##### **3.6.2.1. Zaman Serileri Analizine Dayanan Talep Tahmin Yöntemleri**

Zamanla sırayla toplanan verilere zaman serisi denir. Birçok istatistiksel yöntem, bağımsız ya da ilişkisiz olan verilerle ilgilidir. Belirli bir sitemdeki zaman içinde tekrarlanan verilerin ilişkilendirilebileceđi birçok pratik yöntem vardır, zaman serileri analizleri bu yöntemlerden biridir.

Zaman serilerinin ortaya çıktığı bazı örnekler aşağıda verilmiştir [30] :

- Ekonomi ve finans
- Çevresel modelleme
- Meteoroloji ve Hidroloji
- Nüfus
- Tıp
- Mühendislik
- Kalite kontrol

Zaman serisi analizinin amaçları [30] :

- Açıklama: Özet istatistikler, grafikler çıkartılabilir.
- Analiz ve yorum: Verideki zamana bağlılığı tanımlayan bir model bulunup model yorumlanabilir.
- Tahmin: Seriden bir örnek verildiğinde, sonraki değerler veya gelecekteki değerler tahmin edilebilir.
- Kontrol: Seriyi bir hedefe yaklaştırmak için çeşitli kontrol parametreleri ayarlanabilir. Örneğin, seri bir üretim sürecini kontrol etmek ve kalitesini ölçmek için zaman serileri kullanılabilir.

Bir tahmin modeli geliştirirken her zaman grafiksel gösterimle ve mevcut verilerin analizi ile başlanmalıdır. Bu sayede bir zaman serisinin genel özelliklerinin çoğu görsel olarak görülebilir.

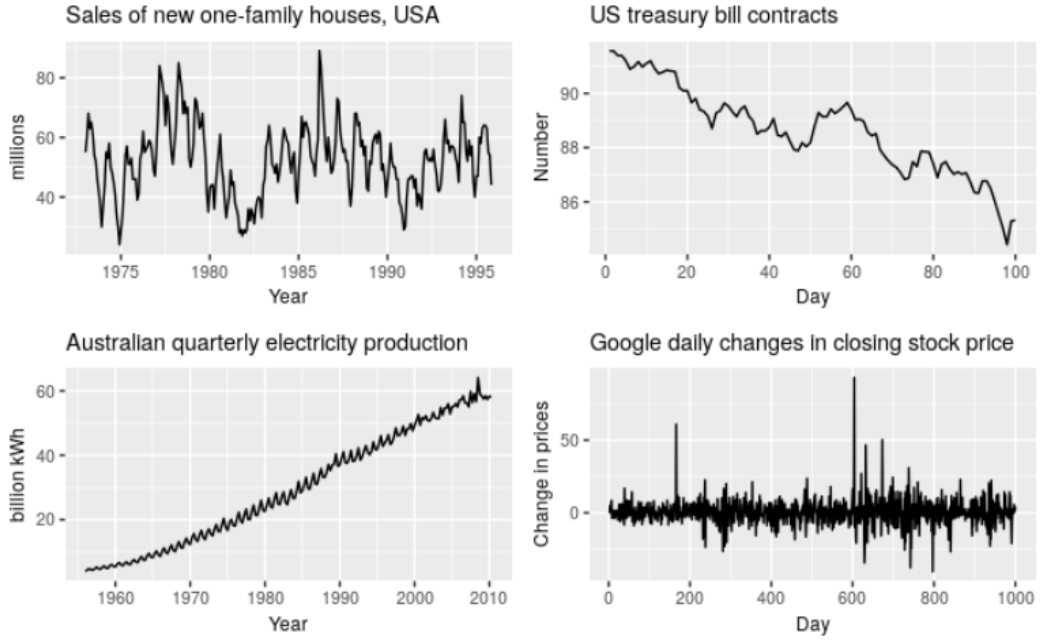
Zaman serilerini anlatırken geçmişe ilişkin talep miktarları aşağıdaki üç bileşenin etkisi altında olabilir [31] :

**1. Trend:** Verilerde uzun vadeli artış veya düşüş olduğunda bir eğilim vardır. Eğilim artan bir trenden azalan bir trende ya da tam tersine giderken “yön değiştiren” olarak tanımlanabilir.

**2. Mevsimsellik:** Bir mevsimsel düzen, zaman dizisi yılın ayı ya da haftanın günü gibi mevsimsel faktörlerden etkilendiğinde meydana gelir. Mevsimsellik her zaman sabit ve bilinen sıklıktadır.

**3. Döngü :** Veriler sabit bir frekansta olmayıp yükselip alçaldığında bir döngü oluşur. Bu dalgalanmalar genellikle ekonomik koşullardan kaynaklanır. Birçok insan döngüsel davranışı mevsimsel davranışlarla karıştırır, ancak bu ikisi oldukça

farklıdır. Eğer dalgalanmalar sabit bir frekansta(zaman aralığında) değilse, o zaman dögüseldir. Eğer frekans deęişmiyorsa ve yükselip alçalma belli tarihler arasındaysa, desen mevsimseldir. Genel olarak, ortalama dögü uzunluğu mevsimsel bir örgütün uzunluęundan daha uzundur ve dögüsel büyüklükler mevsimsel örüntülerin büyüklüğünden daha deęişken olma eğilimindedir.



**Şekil 3.4.** Farklı desenleri gösteren dört zaman serisi örneęi [31]

Pek çok zaman serisi trend, dögü ve mevsimsellik içerir. Bir tahmin yöntemi seçerken, önce verilerdeki zaman serisi modelleri tanımlanmalı sonra desenleri doğru şekilde yakalayabilecek bir yöntem seçilmelidir.

### 3.6.2.1.1. Son Dönem Talebi Yöntemi

Son dönemde gerçekleşen talebin deęişmeyeceğinden hareketle, son dönemin talebini yeni dönemin tahmininde kullanan yöntemdir. Bu yöntemi geçmişe ait verilerin çok deęişmedięi ve belirli bir ortalama da seyrettięi serilerde kullanmak daha doğrudur. Aksi durumda geçmişe ait verileri dikkate almadığından yeni dönemler için tahminler yapılırken son dönemdeki talebi baz almak yanıltıcı olur.



### 3.6.2.1.2. Aritmetik Ortalama Yöntemi

Aritmetik ortalama, bir eğilim sergilemeyen serileri tanımlamak için kullanılabilir; her gözlem için hesaplamada eşit bir ağırlık verir. Metot gelecek dönemin tahminini hesaplarken geçmiş dönemlerin satışların toplar ve ortalamasını alır. Basit ortalama, her biri sabit bir ortalamaya sahip olabilecek farklı serilerin genel seviyelerinin belirlenmesi ve karşılaştırılmasında yardımcı olur [32] .

$$Y_t^* = \frac{\sum_{i=1}^n D_i}{n} \quad (3.1)$$

Eşitlik 3.1’de,

$Y_t^*$  : t. dönem için tahmini talep değeri

$Y_i$  : i. denemdeki satış

n= dönem sayısını ifade etmektedir.

### 3.6.2.1.3. Hareketli Ortalamalar Yöntemi

Bu metot aritmetik ortalama metodunda olduğu gibi, gelecek dönemin talebini kendinden önceki dönemlerin ortalamasını alarak bulmaktadır. Ancak hareketli ortalama metodu yakın geçmişin etkisinin büyük olacağını öngörerek tahmin edilecek dönemden önceki n döneme kadar gerçekleşmiş taleplerin ortalamasını almaktadır.

$$Y_t^* = \frac{\sum_{i=1}^n y_{t-i}}{n} \quad (3.2)$$

Eşitlik 3.2’de,

$Y_t^*$  : t. dönem için tahmini talep değeri

$Y_{t-i}$  : t. dönemden i. dönem öncesinin gerçekleşen talep değeri

n: Hareketli ortalama göz önüne alınacak dönem sayısını ifade etmektedir.

Hareketli ortalama yönteminin özelliği, mevsimlerin talepler üzerindeki etkisini belirgin olarak ortaya çıkarması ve çok eskiye ait geçmiş dönemleri dikkate almamasıdır [25]. Hareketli ortalama yöntemine dayanarak yapılan tahminler, tahmin dönemindeki satış yakın dönemlerin satışlardan etkileniyorsa iyi sonuç verebilir fakat böyle bir durum söz konusu değilse yöntem uzak geçmişi görmezden geldiği için bu yöntemi kullanmak doğru olmayacaktır.

#### 3.6.2.1.4. Ağırlıklı Ortalama Yöntemi

Aritmetik ortalama yönteminde geçmiş dönemlerin ağırlıkları birbirine eşit kabul edilmekteydi oysa ağırlıklı ortalama yönteminin dayandığı temel düşünce geçmişte gerçekleşen taleplerin ortalama olan etkisinin aynı olmadığıdır. Geçmiş dönemlerdeki taleplerin her biri, tahmin edilecek dönem üzerinde dereceli bir etkiye sahipse bir başka deyişle belirli dönemlerin verileri gelecek dönemler için kesin bir fikir veriyorsa ağırlıklı ortalama yöntemi kullanılabilir. Ağırlıklı ortalama yönteminde talep tahmini aşağıdaki gibi hesaplanmaktadır:

$$Y^* = \frac{\sum_{i=1}^n W_i Y_i}{\sum_{i=1}^n W_i} \quad (3.3)$$

Eşitlik 3.3'te,

$Y^*$  : Tahmini talep değeri (Ağırlıklı ortalama)

$Y_i$  : i. dönem için gerçekleşen talep değeri

$W_i$  : i. dönemde gerçekleşen talebin tahmine etkisi (i. dönemin ağırlık katsayısı)

n= Geçmiş dönem sayısını ifade etmektedir.

Ayrıca şu koşullar söz konusudur:

$$0 < W_i < 1 \text{ (} i=1,2,\dots,n \text{)} \quad \text{ve} \quad \sum_{i=1}^n W_i = 1$$

### 3.6.2.1.5. Ağırlıklı Hareketli Ortalama Yöntemi

Bu yöntem ağırlıklı ortama yönteminde olduğu gibi tahmin yapılacak dönemin öncesindeki dönemlere etki oranlarına göre ağırlıklar vermektedir. Ancak hareketli özelliğinden dolayı geçmiş tüm dönemleri değil, en yakın dönemlerdeki talep değerlerini dikkate almaktadır. En yakın dönemlerden kaçının dikkate alınacağı zaman serisinin özelliğine (mevsimsellik, eğilim), ürüne ve müşteriye göre değişebilir. Yöntemde geçmiş dönemlere ağırlık verirken tahmin yapılacak döneme yakın dönemlere daha fazla ağırlık katsayısı verilmektedir. Eğer ürünün talebinde son dönemlerde gerçekleşen satışların etkisinin daha büyük olduğu düşünülüyorsa bu yöntemi kullanılabilir. Ayrıca zaman serisini oluşturan talep verilerinde genel ortalamanın çok üstünde ya da çok altında aşırı değerler varsa bu dönemlerin ağırlık katsayıları düşürülerek sapmalar azaltılabilir. Ağırlıklı hareketli ortalama yönteminde tahmini talep değeri aşağıdaki gibi hesaplanmaktadır:

$$Y_t^* = \sum_{i=1}^n W_i Y_{t-i} \quad (3.4)$$

$Y_t^*$  : t. dönem için tahmini talep değeri (Ağırlıklı hareketli ortalama)

$Y_{t-i}$  : t. dönemden i dönem öncesinin gerçekleşen satış değeri

$W_i$  : i. dönemde gerçekleşen satış değerinin talep tahminine etkisi (i. dönemin ağırlık katsayısı)

n : Ağırlıklı hareketli ortalama göz önüne alınacak dönem sayısı

Ayrıca aşağıdaki koşulların unutulmaması gerekir.

$$0 < W_i < 1 \text{ (} i=1,2,\dots,n \text{)}$$

### 3.6.2.1.6. Üssel Ağırlıklı Hareketli Ortalama Yöntemi

“Üssel Düzeltme ( Exponential Smoothing) Yöntemi” olarak da adlandırılmaktadır. Robert Macaulay tarafından tasarlanan bir yöntemdir. 1931’de II. Dünya Savaşı sırasında Robert G. Brown tarafından geliştirilmiştir. Üssel düzeltme yöntemi, eğilim veya mevsimsellik oluşturan düzensiz verileri izole etmeye çalışır [32] .

Üssel ağırlıklı hareketli ortalama yönteminde genellikle bir önceki dönemde gerçekleşen talep, tahminin yapılmasında en yüksek etki sahibidir. Yöntem iki temel veriyi kullanmaktadır:

Birinci veri olarak yine yakın geçmişe daha fazla ağırlık veren bir yöntemle tahmin yapılacak dönemden bir önceki dönem için tahmini değer hesaplanır (bu yöntem için hareketli ortalama ve ağırlıklı ortalama gibi yöntemler seçilebilir). Hesaplanan bu değer gelecek dönemin tahmini için kullanılmaktadır. Yöntemin kullandığı ikinci veri ise bir önceki dönem gerçekleşen satış değeridir.

Üssel düzeltmenin avantajı, eski verilere gereksinim duymadan hesaplama kolaylığı sağlamasıdır. Yöntemin mantığı son dönemin tahmin edilen ve gerçekleşen satış değerleri arasındaki farkı (tahmin hatasını) belirli bir katsayı ile tahmine yansıtmaktır [25] .

Yöntemde kullanılan  $\alpha$  ağırlık katsayısı 0 ile 1 arasında olmalıdır. Yüksek  $\alpha$  değerleri dalgalanma olan serilerde tahmin yapılırken kullanılır. Bu durumda son dönemde gerçekleşen talep değerine ağırlık verilmiş olunur. Düşük  $\alpha$  değerleri ise daha düzgün serilerde kullanılmaktadır. Bu durumda sadece yakın dönemlerin talebi değil geçmiş dönemlerin talebi de hesaba katılmış olunur. Üssel düzeltme yöntemiyle talep hesaplama formülü ve açıklaması aşağıdadır:

$$Y_{t+1}^* = \alpha Y_t + (1 - \alpha) Y_t^* \quad (3.5)$$

$Y_t$  : t. dönem gerçekleşen talep değeri

$Y_{t+1}^*$  : t+1. dönemin tahmini talebi

$Y_t^*$  : t. dönemin tahmini talebi ( bu tahmin değeri aritmetik, hareketli ya da ağırlıklı ortalama yöntemlerinin herhangi birisiyle hesaplanabilir)

### 3.6.2.1.7. Holt'un Lineer Trend Modeli

Holt'un aynı zamanda "doğrusal üssel düzeltme" olarak da bilinen iki parametrelili bu modeli, eğilime sahip zaman serilerinde tahmin yapabilmek için kullanılan popüler bir düzeltme modelidir. Yöntemde nihai bir tahminde bulunmak için birlikte çalışan üç ayrı denklem vardır. Birincisi, son dönemdeki eğilim için son düzleştirilmiş değeri doğrudan ayarlayan seviye denklemdir. İkinci denklem ise zaman içinde oluşan eğilimi son iki düzleştirilmiş değer arasındaki fark olarak ifade eder ve eğilimi günceller. Son olarak üçüncü denklem ise tahminin oluşturulmasında kullanılır [33] .

$$\text{Seviye Denklemi : } L_t = \alpha Y_t + (1-\alpha) (L_{t-1} + T_{t-1}) \quad (3.6)$$

$$\text{Eğilim Denklemi : } T_t = \beta (L_t - L_{t-1}) + (1-\beta) T_{t-1} \quad (3.7)$$

$$\text{Tahmin Denklemi : } Y_{t+m}^* = L_t + T_t m \quad (3.8)$$

Burada  $\alpha$  düzgünleştirme parametresi,  $\beta$  ise eğilim için düzgünleştirme parametresidir.  $L_t$  zaman serisinin t anındaki seviyesini ifade ederken  $T_t$  serinin t zamanındaki eğilimini belirtmektedir.  $\beta$  parametresi 0 ile 1 arasında değer almaktadır.

### 3.6.2.1.8. Holt-Winter Mevsimsellik Modeli

Eğilim göstermesinin yanı sıra mevsimsellik de gösteren zaman serileri için geliştirilmiş bir yaklaşımdır.

Holt Winter modeli seriye üç üssel düzeltme formu uygulamaktadır. İlk olarak, serinin ortalamasını düzeltir. İkinci olarak eğilim düzeltilir ve son olarak mevsimsel olan serilerin her biri mevsimsel tahminler yapmak için ayrı ayrı düzeltilir.

$$Y_{t+m}^* = L_t + T_t m + S_{t-s+m} \quad (3.9)$$

$$L_t = \alpha (Y_t - S_{t-s}) + (1 - \alpha) (L_{t-1} + T_{t-1}) \quad (3.10)$$

$$T_t = \beta (L_t - L_{t-1}) + (1 - \beta) T_{t-1} \quad (3.11)$$

$$S_t = \gamma (Y_t - L_t) + (1 - \gamma) S_{t-s} \quad (3.12)$$

### 3.6.2.2. Nedensel Yöntemler

Nedensel yöntemler tahmin edilecek değişken (bağımlı değişken) ile bu değişkeni etkileyecek olan diğer faktörler(bağımsız/açıklayıcı değişkenler) arasındaki ilişkileri ortaya çıkarmak için geliştirilmiş istatistiksel yöntemlerdir. Nedensel yöntemlerle değişkenler arasındaki ilişkinin gücü ölçülebilir veya ilişkilerin tesadüfen oluşup oluşmadığı istatistiksel olarak test edilebilir.

Nedensel modeller, güçlü nedensel ilişkiler mevcut olduğunda, ilişkilerin yönelimleri bilindiğinde, nedensel değişkenlerin tahmin üzerinde büyük değişiklikler yapacağı beklendiğinde çok faydalıdır. Nedensel yöntemler arasında en sık kullanılan metotlar regresyon analizi ve korelasyon analizidir.

### 3.6.2.3. Regresyon Analizi

Regresyon analizi, aralarında sebep-sonuç ilişkisi bulunan iki ya da daha fazla değişken arasındaki ilişkiyi ölçmek ve bu ilişkiyi kullanarak tahminlerde bulunulmasına olanak veren istatistiksel bir yöntemdir.

Regresyon analizindeki bağımlı değişkenler anlamaya veya tahmin edilmeye çalışılan değişkenlerdir. Bağımsız değişkenler ise tahmin edilmeye çalışılan bağımlı değişken

üzerinde etkisi olduğu düşünölen deęişkenlerdir. . Eęer model tek bir baęımsız deęişkendenden oluşuyorsa tek deęişkenli regresyon, birden fazla baęımsız deęişkendenden meydana geliyorsa çok deęişkenli regresyon analizi olarak isimlendirilmektedir. “Çok Deęişkenli Regresyon Analizi” Bölüm 5.8’de uygulamalı olarak anlatılmıştır.

Regresyon analizinde deęişkenler arasındaki ilişkiyi matematiksel olarak ifade edebilmek için deęişken verileri bir serpilme diyagramında noktalarla göstermek gerekir. Örneęin, serpilme diyagramındaki noktalar bir doğru etrafında toplanmış ise doğrusal bir fonksiyon kullanmak daha uygun olacaktır. Eęer noktalarda bükölmeler oluşmuşsa eğrisel bir fonksiyon kullanmak gerekir. Ayrıca bükölme noktalarının sayısına göre fonksiyonların kaçınıcı dereceden olduğu da belirlenebilir (Bir bükölme noktası ikinci dereceden, iki bükölme noktası ise üçüncü dereceden bir fonksiyonun kullanılmasını gerektirir) [34] .

Regresyon analizinde deęişkenler arasındaki doğrusal ya da eğrisel ilişkileri matematiksel olarak ifade eden bazı regresyon denklemleri aşağıda verilmiştir:

$$\text{Basit Doğrusal Regresyon} : Y = a + bX \quad (3.13)$$

$$\text{Çoklu Doğrusal Regresyon} : Y = a + b_1X_1 + b_2X_2 + b_3X_3 + \dots + b_nX_n \quad (3.14)$$

$$\text{Üssel Regresyon} : Y = a + b_1^x \quad (3.15)$$

$$\text{Eğrisel Regresyon} : Y = a + b_1X_1 + b_2X_2^2 + b_3X_3^3 + \dots + b_nX_n^n \quad (3.16)$$

Örnek olarak basit doğrusal regresyon modelinden bahsetmek gerekirse, model bir adet baęımlı ve bir adet baęımsız deęişken içeren bir modeldir.  $Y = a + bX_i + e$  şeklinde ifade edilir. Formölün açıklaması aşağıda gösterilmiştir:

$Y$  = Belirli bir hataya sahip olunduęu düşünölen baęımlı deęişkendir. (Tahmini talep)


$X$  = Baęımsız deęişkendir.

$a$  = Regresyon denkleminin sabit terimidir.

$b$  = Regresyon katsayısıdır. Bağımsız değişkendeki (  $X$ 'de) bir birim değişiminin bağımsız değişkende (  $Y$ 'de) meydana getirdiği değişim miktarını ifade eder.

$e$  = Regresyon denklemindeki hata terimidir.

Matematiksel fonksiyonun parametreleri olarak da geçen  $a$  ve  $b$  değerlerini bulmak için En Küçük Kareler(EKK) yöntemi adı verilen bir yöntem kullanılmaktadır. EKK yöntemi belirli bir noktalar kümesine en uygun eğriyi bulmak için geliştirilmiştir. Yöntem hata terimlerinin karelerini en küçükleyecek şekilde parametrelerin tahmini değerlerinin hesaplanmasını sağlamaktadır. Diğer bir ifadeyle EKK yöntemi kullanılarak yapılan tahmin değerlerinin gerçek talep değerlerinden sapmalarının kareleri toplamı en küçük olacaktır. Bu durum Şekil 3.5' te gösterilmiştir.



Şekil 3.5. Regresyon doğrusu

Hata değerlerinin kareleri toplamını minimum yapan doğru denklemi bulunduğundan sonra talep tahmini yapılabilir. Tahmin yapılırken parametreler aşağıdaki gibi bulunabilir ve tahmin edilmek istenen dönemin numarası bağımsız değişken olan  $X$ 'in yerine yazılarak tahmin yapılabilir.

$Y = a + bX$  denklemdeki parametreler aşağıdaki formüllerle bulunur:



$$b = \frac{n\sum XY - (\sum X)(\sum Y)}{n\sum X^2 - (\sum X)^2} \quad (3.17)$$

$$a = \frac{\sum Y}{n} - b \frac{\sum X}{n} \quad (3.18)$$

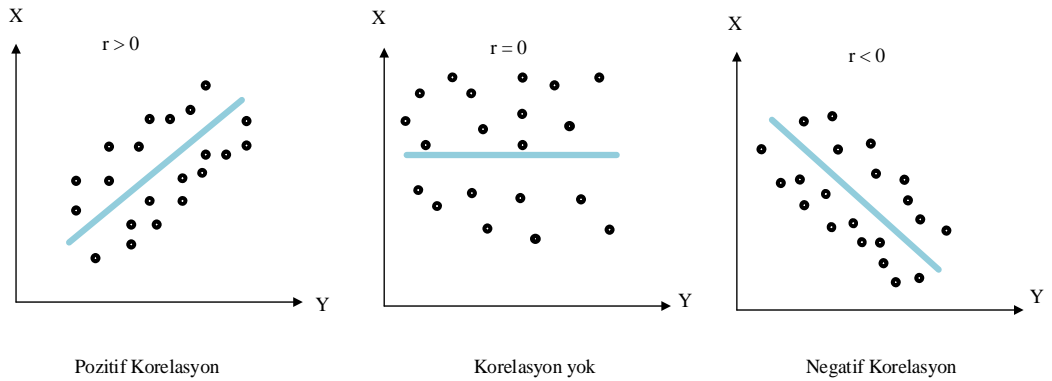
X : Dönem numaraları

Y : Geçmiş talep değerleri

n : Geçmiş talep dönemi sayısını ifade etmektedir.

#### 3.6.2.4. Korelasyon Analizi

Korelasyon analizi, gelecekteki değeri tahmin edilmek istenen değişkenle, onu etkileyen değişken ya da değişkenler arasındaki ilişkiyi test etmek, varsa bu ilişkinin derecesini ölçmek için kullanılan istatistiksel bir yöntemdir. Korelasyon analizinde amaç; bağımsız değişken (X) değiştiğinde, bağımlı değişkenin (Y) ne yönde değişeceğini analiz etmektir. Korelasyon analizi sonucunda, değişkenler arasında ilişkinin olup olmadığı, eğer ilişki varsa derecesinin ne olduğu korelasyon katsayısı (r) ile hesaplanmaktadır. Şekil 3.6'da farklı korelasyon durumları gösterilmiştir.



Şekil 3.6. Farklı korelasyon durumları

Şekil 3.6'ya bakıldığında; değişkenler arasında pozitif bir ilişkinin olması durumunda X değişkeninin değeri artarken Y değişkeninin de değerinin arttığı, negatif bir ilişkinin olması durumunda değişkenlerin birine ait değerlerin artması durumunda diğer değişkene ait değerlerin düştüğü görülmektedir.

Korelasyon katsayısı, bağımsız değişken (X) yerine tahmin edilmek istenen dönem numaraları yazılarak aşağıdaki gibi hesaplanabilir:

$$r = \frac{n\sum XY - (\sum X)(\sum Y)}{\sqrt{[n\sum X^2 - (\sum X)^2][n\sum Y^2 - (\sum Y)^2]}} \quad (3.19)$$

Korelasyon katsayısı -1 ile +1 arasındadır. r'nin -1'e yakın olması değişkenler arasında çok güçlü bir negatif doğrusal ilişki olduğuna, +1'e yakın olması da çok güçlü bir pozitif doğrusal ilişki olduğuna işaret etmektedir.

Korelasyon katsayısı için şu ilişki ve ifadeler yazılabilir [25] :

$0,9 \leq r < 1$  ise X-Y arasında çok sıkı ilişki vardır.

$0,7 \leq r < 0,9$  ise X-Y arasında sıkı ilişki vardır.

$0,4 \leq r < 0,7$  ise X-Y arasında orta dereceli ilişki vardır.

$0,2 \leq r < 0,4$  ise X-Y arasında zayıf ilişki vardır.

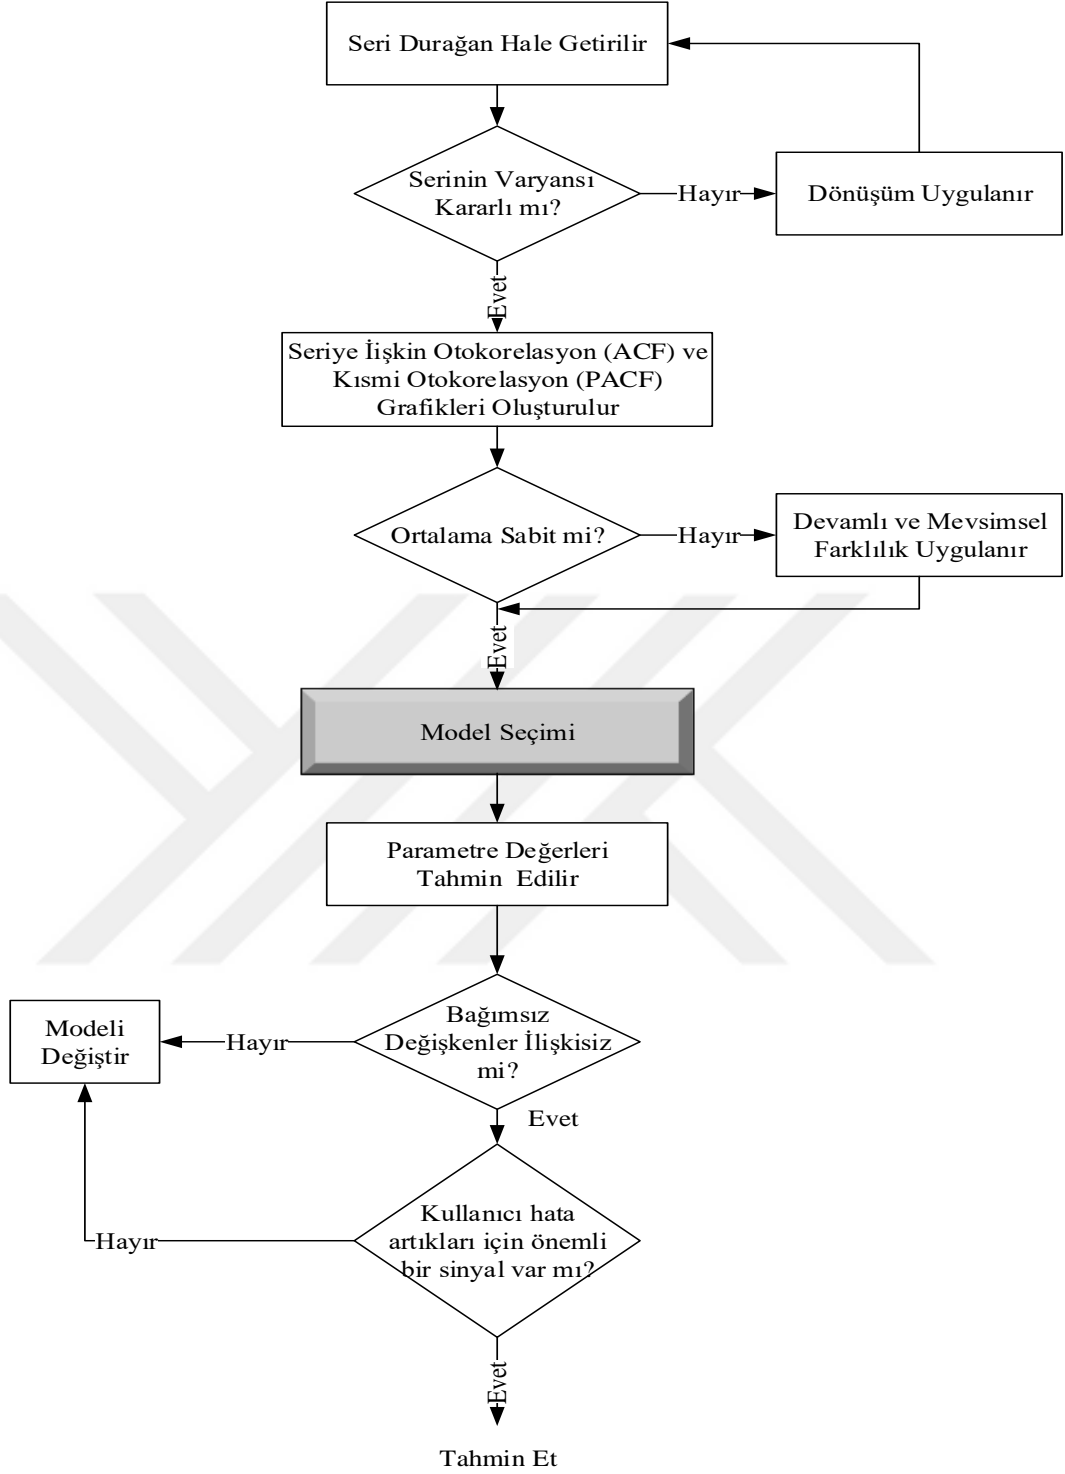
$0 \leq r < 0,2$  ise X-Y arasında çok zayıf ilişki vardır.

### 3.6.2.5. Box Jenkins Yöntemleri

Box-Jenkins (B-J) yöntemi tek değişkenli zaman serilerinin ileriye dönük tahmininde kullanılır. B-J yöntemleri eşit zaman aralıklarıyla elde edilen gözlem değerlerinden meydana gelen kesikli ve durağan zaman serilerinin ileriye dönük tahmin modellerinin kurulmasında ve tahminlerin yapılmasında sistemli yaklaşım göstermektedir [35] .

Zaman serisinin durağan olduğunun söylenebilmesi için, ortalamasında ve varyansında sistematik bir değişim olmaması gerekir. Bir seri sabit bir büyüme ya da genel bir trend gösteriyorsa ya da bir seviyeden bir başka seviyeye geri dönüyorsa, bu yapıdaki seriler durağan bir seriye dönüştürülmeden modellenemezler [8] .

Şekil 3.5'te Box-Jenkins modelinin oluşturulma aşamaları gösterilmektedir. Öncelikle durağan olmayan seriler durağan hale getirilmektedir. Model belirleme aşamasında zaman serisine en uygun Box-Jenkins modeli belirlendikten sonra belirlenen modele ilişkin parametreler tahmin edilir. Daha sonra modelin veri setine uygunluğu istatistiksel yöntemlerle test edilir. Model uygun bulunursa bir sonraki aşamaya geçilir, uygun bulunmazsa yeni bir model belirlemek için seri tekrar kontrol edilir. İşlemler sonucunda uygun bulunan model tahmin için kullanılabilir.



Şekil 3.7. Box-Jenkins modelleme yaklaşımı [36]

Box – Jenkins modelleri, otoregresif modeller (AR), hareketli ortalama modelleri (MA), Otoresif hareketli ortalama modelleri (ARMA) ve durağan olmayan serilerde uygulanan (ARIMA) modellerinden oluşmaktadır.

### 3.6.2.5.1. Otoresif Model – AR(p) Modelleri

Çoklu bir regresyon modelinde, ilgilenilen değişken doğrusal bir belirleyici kullanarak tahmin edilmektedir. Otoresif modelinde ise ilgilenilen değişken, değişkenin geçmiş değerlerinin doğrusal bir kombinasyonu kullanılarak tahmin edilmektedir. Otomatik regresyon terimi, değişkenin kendisine karşı bir regresyonu olduğunu gösterir [31]. AR (p) modelleri aşağıdaki şekilde yazılabilir:

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (3.20)$$

### 3.6.2.5.2. Hareketli Ortalamalı Model – MA(q) Modelleri

Tahmin değişkeninin geçmiş değerlerini kullanmak yerine, regresyona benzer hareketli ortalamalı bir model ile geçmişteki tahmin hatalarını kullanır. MA (q) modeli aşağıdaki gibi yazılabilir:

$$y_t = c + \varepsilon_t + \phi_1 \varepsilon_{t-1} + \phi_2 \varepsilon_{t-2} + \dots + \phi_q \varepsilon_{t-q} \quad (3.21)$$

Eşitlik 3.21’de  $y_t$  son birkaç tahmin hatasının ağırlıklı hareketli ortalaması olarak düşünülebilir. Bununla birlikte, hareketli ortalama modelleri, Bölüm 3.6.2.1.3’de anlatılan hareketli ortalama yöntemi ile karıştırılmamalıdır. Hareketli ortalama yöntemi gelecekteki değerleri tahmin etmek için kullanılırken hareketli ortalama modelleri geçmiş değerlerin eğilim döngüsünü tahmin etmek için kullanılır [31].

Formüldeki  $\varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-q}$  hata terimlerini,  $\phi_1, \phi_2, \dots, \phi_q$  değerleri hata terimlerinin katsayılarını göstermektedir.

### 3.6.2.5.3. Otoresif Hareketli Ortalamalı Model – ARMA(p,q) Modelleri

Çoğu durumda seriler tek başına AR( p) veya MA(q) süreçleri tarafından ifade edilemezler. Bu yüzden bu seriler otoresif ve hareketli ortalama modellerinin birleşimi olan ARMA modeli şeklinde ifade edilmeye çalışılır. AR ya da MA modelini kullanarak çok sayıda parametreyi gerektiren veriler, bir ARMA modeli kullanılarak sadece birkaç parametre ile modellenmektedir. Genelde, modelde çok sayıda parametrenin bulunması tahminde etkinliği azaltır [37] .

Model, zaman serisini kullanarak t dönemi için tahmin yaparken p dönem önceki gözlem değeri ile q dönem önceki hata değerinin toplamından oluşmaktadır.

ARMA (p, q) modelleri aşağıdaki gibi ifade edilebilir:

$$y_t = c + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t - \phi_1 \varepsilon_{t-1} - \dots - \phi_q \varepsilon_{t-q} \quad (3.22)$$

### 3.6.2.5.4. Otoresif Bütünleşik Hareketli Ortalamalı Model– ARIMA(p, d, q) Modelleri

ARIMA modelinde bir zaman serisi üç bileşene ayrılmıştır. p, gözlemlerin zaman içinde birbirine olan yakınlığından hareketle birbirleriyle nasıl ilişkili olduklarını açıklarken, d, bir zaman serisini durağan yapmak için kullanılan farklılaştırma bileşenidir. q ise serideki aşırı yükselme ya da alçalmaları tanımlayan hareketli ortalama bileşenidir.

*Durağanlık Varsayımı:* İlgilenen veri setinin durağan olması, zaman içinde sabit bir ortalama ve varyansa sahip olmasıdır. Bir veri seri başlangıçta durağan değilse, durağanlık modelin “d” bileşeni tarafından temsil edilen “farklılık” adı verilen bir

işlemlerle elde edilir.  $d$  parametresi serinin kaç kez farkının alındığını belirtir. Fark işlemi aşağıdaki şekilde ifade edilir:

$$\Delta Y_t = Z_t = Y_t - Y_{t-1} \quad (3.23)$$

Eşitlik 3.23'te  $\Delta$ , fark alma operatörünü ifade etmektedir.  $Z_t$  farkı alınmış serinin  $t$  anındaki tahmini değeridir. Eşitliklerden tahmin edilen  $Z_t$  değerleri durağan bir seri oluşturuyorsa  $d=1$  alınır, eğer seri durağan değilse bir kez daha fark alınır. Bu işlemlerin denklemleri aşağıdadır:

$$\Delta^2 Y_t = W_t = Z_t - Z_{t-1} \quad (3.24)$$

$$\Delta^2 Y_t = W_t = (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2}) \quad (3.25)$$

### 3.6.2.6. Yapay Zekâ Çözümleri

Yapay zekâ ile geliştirilen uygulamalar bugün güncel hayatın birçok alanında sıkça kullanılmaktadır. Talep tahmininde en çok kullanılan yapay zekâ çözümleri bulanık mantık ve yapay sinir ağlarıdır.

#### 3.6.2.6.1. Bulanık Mantık


Bulanık mantık (BM) yaklaşımı günlük hayatta kesin olarak bilinemeyen, elde yeterli verinin bulunmadığı, belirsizlik altında olan ve fazla karmaşık durumlarda çok etkili olabilir. BM kusurlu bilgilerin mantıklı bir şekilde kullanılmasına izin vererek karmaşıklığı azaltmaktadır.

Bazı talep tahmin çalışmaları belirsizlik altında yapılabilir ve geleneksel yöntemlerle modellemek çok karmaşık olabilir. Bulanık yaklaşımlar esnek doğaları sayesinde bu tarz problemlere daha kolay modelleme imkânı sağlayabilir.

Bulanık mantık yaklaşımı algoritmik biçimde insan karar ve değerlendirme sürecini temsil etmektedir. İnsan mantığının matematiksel bir gösterimidir [38] .

Bulanık küme teorisi, klasik küme teorisinin bir genellemesi olarak düşünülebilir. Klasik küme teorisinde bir elemanın kümeye üyelik derecesi  $\{0, 1\}$  şeklinde ifade edilir ve nettir. Bir başka deyişle klasik küme teorisinde evrenin bir ögesi kümeye aittir veya kümeye ait değildir. Bulanık küme teorisinde, bir elemanın ilişkisi sürekli değişebilir [39] .

Üyelik derecelerinden 1 değeri, tam üyelik olması durumunu gösterirken, 0 değeri üye olmama durumunu göstermektedir. Örneğin bu kişi uzun boylu mu? Sorusunun birçok cevabı vardır. 190 cm'den büyük birisi tüm dünyada uzun olarak kabul edilmektedir. Yine 180 cm olan birisinin de uzun olduğu düşünülürken, 160 cm'nin altında olan birisinin genellikle uzun olduğu düşünülmez. Bu durum bir grafik ile açıklanabilir [40].



**Şekil 3.8.** İnsan boyu için bulanık yaklaşım [40]



1965 yılında ilk kez Lotfi A. Zadeh, bulanık küme teorisinden bahsetmiştir. Zadeh, geleneksel bilgisayar mantığının öznel veya belirsiz fikirleri temsil eden verileri kullanamadığını gözlemlemiş, bu nedenle bilgisayarların, insanın akıl yürütme sürecine benzer şekilde veriler arasındaki farkları belirleyebilmesi için bulanık mantık yaklaşımını ortaya koymuştur.

Bulanık yaklaşımda problemin gerekleri ve kısıtları göz önünde bulundurularak üyelik fonksiyonu tasarlanır. Bulanık mantık, üyelik deneyimleri ve bulanık kurallar yoluyla insan deneyimlerini ve tercihlerini uygulayabilir. Sistem uzman olmayan bir kullanıcı için bile anlaşılır hale gelebilir çünkü bulanık mantık kavramsal olarak anlaşılması kolay bir yaklaşımdır, sıradan bir dile dayanmaktadır, kesin olmayan verilere karşı toleranslıdır ve belirsiz süreçleri tanımlama yeteneği sağlar.

#### **3.6.2.6.2. Yapay Sinir Ağları**

Yapay sinir ağları, 4. bölümde ayrıntılı olarak anlatılmıştır. 5. bölümde ise YSA kullanılarak iş makineleri sektöründe talep tahmin problemi çözülmüştür.

### **3.7. Tahmin Yöntemlerinin Doğruluğunun Ölçülmesi**

Talep tahminleri yapılırken tahmin yöntemlerinden hangisi kullanılırsa kullanılsın bulunan tahmini değerler gerçekleşen değerler ile birebir örtüşmez. Yapılan tahminlerde mutlaka belirli bir hata oluşmaktadır. Bu nedenle tahmin çalışmasının doğruluğunun ölçülmesi gerekmektedir.

Tahminin hatası belirli bir t zamanında gerçekleşen talep değeri ile t zamanı için yapılan talep tahmin değeri arasındaki farktır.

$$h_t = YV_t - YE_t \quad (3.26)$$

$YV_t$ , t anında gerçekleşen talep değerini,  $YE_t$  ise t anındaki tahmini değeri göstermektedir.  $h_t$  ile gösterilen tahmin hatası talepten tahminin çıkarılması ile

bulunur. Bu farkı matematiksel olarak ifade edebilmek ve hata oranları üzerinden tahmin doğruluğunu değerlendirebilmek için birçok ölçüm kriteri geliştirilmiştir.

### 3.7.1. Ortalama Hata (ME)

Ortalama hata tüm hata değerlerinin aritmetik ortalamasını alan bir ölçüttür. Hata değerleri pozitif ya da negatif değerler alabilmektedir. Ortalama hata yöntemi genellikle olumlu olmayan bir sayıyla sonuçlanır, çünkü pozitif ve negatif değerler birbirini iptal eder. ME (Mean Error) ölçütünün formül gösterimi aşağıdaki gibidir:

$$ME = \frac{1}{n} \sum_{i=1}^n h_i \quad (3.27)$$

### 3.7.2. Ortalama Mutlak Hata (MAE)

Ortalama mutlak hata yöntemi, ortalama hata yöntemindeki durumu düzeltmek için hata değerlerinin mutlak değerlerini alarak negatif işaretlerden kurtarır. Yöntem mutlak hata değerlerinin aritmetik ortalamasını aldığı için daha olumlu ortalama hata sonuçları elde edilir. MAE (Mean Absolute Error) ölçütünün formül gösterimi aşağıdaki gibidir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |h_i| \quad (3.28)$$

### 3.7.3. Ortalama Hata Karesi (MSE)

Bu ölçütün farkı hata değerlerinin karelerinin ortalamasını almasıdır. Tahmin performanslarını ölçmek için sıkça kullanılan bir ölçüm kriteridir. Ölçütün dezavantajı

ise tek bir kötü tahmin olsa bile, tahmin değerinin karesi alındığından bu hata değerini daha da büyütür. MSE (Mean Square Error) ölçütünün gösterimi aşağıdaki gibidir:

$$MSE = \frac{1}{n} \sum_{i=1}^n h_i^2 \quad (3.29)$$

#### 3.7.4. Ortalama Mutlak Hata Yüzdesi (MAPE)

Ortalama mutlak hata yüzdesi ölçütü tahmin doğruluğunu yüzdesel olarak ölçer. Bunu yaparken her bir zaman periyodu için mutlak hata değerlerini gerçekleşen değerlere böler ve yüzdesini alır. MAPE (Mean Absolute Percentage Error) ölçütünün formül gösterimi aşağıdaki gibidir:

$$MAPE = \left[ \frac{1}{n} \sum_{i=1}^n \frac{|h_i|}{YVt} \right] * 100 \quad (3.30)$$

Talep doğruluğu ölçülürken en sık MAPE ölçütü kullanılmaktadır çünkü insanlar yüzde cinsinden daha rahat düşünürler bu da MAPE ölçütünün yorumlanmasını kolaylaştırır. Talep hacmini bilmeye gerek kalmadan yüzdeli ifadelerle yöneticilere bilgiler verilebilir. Örneğin, yöneticiye “4000 adetten aşağıda kaldık” demek yerine “% 5’ten az kaldık” dendiğinde yönetici ürünün yıllık satış adedini bilmeseyse bile kolaylıkla çıkarımlar yapabilir.

MAPE talep miktarı düşük olan tahminler yapıldığında kullanılmamalıdır. Gerçekleşen satış, denklemin paydasında olduğundan gerçekleşen talep sıfır olduğunda MAPE tanımsız kalacaktır. Ayrıca gerçekleşen değerler sıfır olmayıp çok küçük değerler olsa bile MAPE sık sık aşırı değerler alacaktır. Bu hassasiyet MAPE’yi düşük hacimli veriler için bir hata ölçüsü olarak kullanmakta değersiz kılmaktadır.

## 4. YAPAY SİNİR AĞLARI

### 4.1. Yapay Zekâ Bilimi

Yapay sinir ağıları, yapay zekâ (YZ) biliminin altında bulunan bir araştırma alanıdır. Yapay sinir ağıları anlatılmadan önce yapay zekâ biliminden bahsetmek yerinde olacaktır. Zekâ insanın düşünme, akıl yürütme, kavrama, öğrenilenden yararlanabilme ve sonuç çıkarma yeteneklerinin tümüdür. Belirli bir konuda çalışılarak, eğitilerek elde edilen bilgi birikimlerle zekâ geliştirilebilir.

İnsan beyninin nasıl öğrendiğinin ve nasıl tecrübe ettiğinin modellenmesi üzerine yapılan çalışmalar yapay zekâ bilimini ortaya çıkarmıştır. Teknolojinin geldiği bu noktada bilgisayarlar ve bilgisayar sistemleri yaşamın vazgeçilmez bir parçası haline gelmiştir. Bilgisayarlar büyük miktardaki verileri filtreleyerek özetleyen, bu bilgileri karar vermek ve yorum yapmak için kullanan sistemler haline gelmiştir. İşte bilgisayarlara bu özellikleri edindiren çalışmalar “yapay zekâ” çalışmaları olarak bilinmektedir.

YZ teknolojilerinin en yaygın kullanılan ve en çok araştırılan beş alt dalı aşağıdaki gibi özetlenebilir:

#### i) Makine Öğrenmesi Ve Yapay Sinir Ağları

Makine öğrenmesi ve Yapay Sinir Ağları, bilgisayarların olayları öğrenmesini sağlayan teknolojidir. Genellikle örnekler kullanılarak olayların girdi ve çıktıları arasındaki ilişkiler öğrenilir. Öğrenilen bilgiler ile benzer olaylar yorumlanarak kararlar verilir veya problemler çözülür [41] . Çalışmanın konusu yapay sinir ağıları olduğu için daha sonra ayrıntılı olarak açıklanacaktır.

## **ii) Uzman Sistemler**

Uzman sistemler, insan tecrübe ve deneyimlerine dayanan problem çözmeye ve bazı aktiviteleri gerçekleştirmeye yönelik bilgi tabanlı bilgisayar programlarıdır. Uzman sistemler, uzmana ait programlanabilen kararların bir kısmının bilgi sistemini üstlenmekle görevlidir. Uzman sistemler, analitik modelleri kurulamayan bir çok gerçek hayat problemlerinin, sezgisel modellerle ifadesini ve çözümünü mümkün kılmaktadır [42] .

## **iii) Genetik Algoritmalar**

Canlılardaki genetik süreci bilgisayar ortamına taşıyan bu yaklaşım üzerindeki çalışmalar, özellikle son 30 yıl içerisinde oldukça hızlı bir ivme kazanmıştır. Genetik algoritmayı 1970'li yıllarda Hollanda başlatmış olup, onun öğrencisi olan Golberg ise 1989'lu yıllarda genetik algoritmayı bir çok alanda uygulamaya koymuştur. Genetik algoritma, doğadaki canlıların geçirdiği evrim sürecini örnek alarak matematiksel modeli kurulamayan veya çözüm alanı çok geniş olan problemlerin çözümünde kullanılan tekniklerdir. Temeli rastgeleliğe dayanan genetik algoritmalar oldukça başarılı çözümler üretebilmektedir. Basit bir genetik algoritma beş elemandan oluşur. Bu elemanlar sırasıyla; random sayı üreticisi, uygunluk kontrolü mekanizması, üreme, crossover ve mutasyon operasyonları ile genetik operatörlerdir [42] .

## **iv) Bulanık Mantık**

Bölüm 3.6.2.6.1' de anlatıldığı gibi bulanık mantık, kesin olarak bilinmeyen, net bir şekilde ifade edilemeyen olaylar hakkında karar vermek için geliştirilmiş bir yaklaşımdır. Klasik mantığa göre bir ifade doğru ise 1, tamamen yanlış ise 0 değerindedir. Bulanık mantık ise doğruluk derecelerine

dayanan bir yaklaşımdır. Günümüzde birçok olay belirsizdir. 0 ve 1 gibi mutlak tanımlamalar yapılamaz.

Örneğin; bir bilgisayar için sadece uzun-kısa ya da sıcak soğuk olabilen bir durum, bulanık mantık kullanılarak uzun-ortadan uzun-orta-ortadan kısa-kısa ya da sıcak-ılık-az soğuk-soğuk-çok soğuk gibi ara değerlere sahip olabilir [8]. Bu açıdan bakıldığında bulanık mantık insan beyninin çalışma sistemine yakın bir yaklaşımdır.

#### v) Zeki Etmenler

Zeki etmenler, insan üzerindeki bilgi yükünün azaltılmasını amaçlamaktadır. Bilgi teknolojilerindeki yazılımsal ve donanımsal gelişmeler bilgi akışının sürekli olarak hızlanmasına neden olmuş bu da kullanıcılar tarafından hazmedilmesi ve anlaşılması zor bir durum haline gelmiştir. Verilerin filtrelenerek azaltılması ve kullanıcıların ham, karmaşık veriler yerine işlenmiş bilgi ile buluşturulması zeki etmenlerin hedeflerindedir.

### 4.2. Yapay Sinir Ağlarının Genel Tanımı

Yapay sinir ağları insan beyninin bilgileri analiz etme ve işleme şeklini simüle etmek için tasarlanmış bilgisayar sistemleridir. İnsan hesaplamasıyla ya da istatistiksel hesaplama yöntemleriyle zor ya da imkânsız olan sorunları çözerler. YSA, veri sayısı fazla olduğunda daha iyi sonuçlar üretebilir çünkü kendi kendine öğrenme yeteneğine sahiptir.

### 4.3. Yapay Sinir Ağı Tanımı ve Görevi

Bilgisayarların insanlarla karşılaştırıldığında daha iyi ve daha hızlı yapabileceği pek çok şey bulunmaktadır. Örneğin karekök vs. gibi matematiksel işlemlerin hesaplanması bilgisayar yardımıyla daha kolay olmaktadır. Fakat muhteşem

tasarlanmış insan beyni hala sağduyu, ilham ve hayal gücü söz konusu olduğunda bilgisayarlardan çok daha öndedir. YSA bilgisayarları daha insani yapmaya ve makinelerin insanlara daha çok benzemesine yardımcı olmaktadır.

YSA'nın insan beynine benzer bazı davranış özellikleri aşağıdaki gibidir;

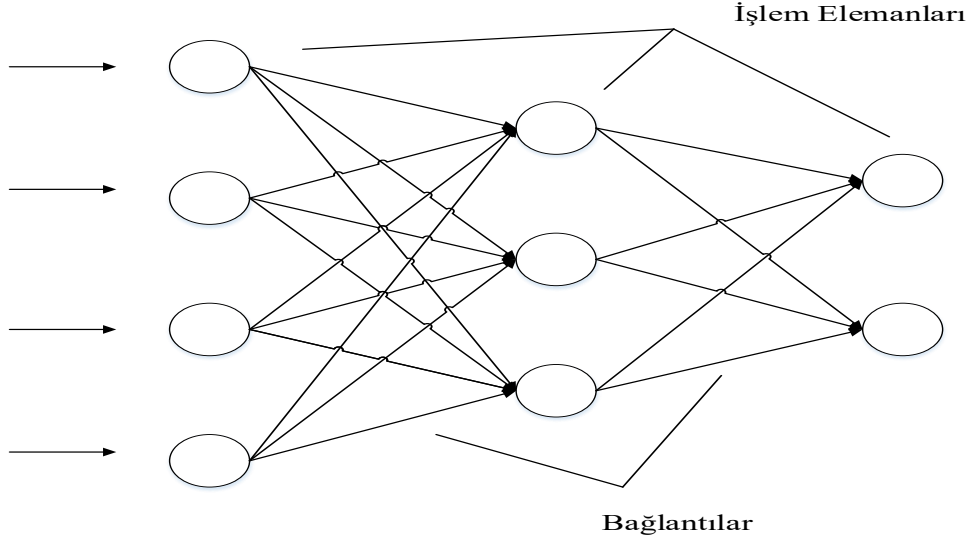
- Öğrenme
- Sınıflandırma
- Özellik çıkarma
- Genelleme
- Optimizasyon

İnsan beyni için en önemli olan yetenek öğrenmektir, insan beyni geçmişte kaydettiği bilgileri birbirleriyle ilişkilendirerek öğrenir. Bilgileri birbiriyle karşılaştırır, birleştirir ve yeni fikirler üretir. İşte insan zihnini özel yapan şey budur. Öte yandan bilgisayarlara milyonlarca dosya kaydedilmektedir. Fakat bilgisayarlar bunlar arasında ilişki kurup düşünemezler. Bilgisayarlar bilgileri saklamakta, sorulan sorulara o bilgileri süzerek aynen cevap vermektedir.

Yapay sinir ağları çalışırken bilgileri anlamak için farklı matematiksel işlem katmanları kullanmaktadır. Tipik olarak yapay sinir ağı, bir dizi katmanda düzenlenmiş binlerce-milyonlarca yapay hücrenin herhangi bir yerinde bulunmaktadır.

Teknik olarak yapay sinir ağının görevi, dış dünyadan giriş katmanı tarafından alınan çeşitli verilerin ağ tarafından işlenip öğrenilmesiyle çıktı olarak kullanılabilen bilgilere dönüştürmektir.

Yapay sinir ağlarının çoğu bir katmandan diğerine tamamen bağlıdır ve bu bağlantıların ağırlık değerleri vardır. Ağırlık değerleri arttıkça bir birimin bir başkası üzerindeki etkisi insan beynine benzer şekilde artmaktadır. Veriler bu birimlerden geçerken yapay sinir ağı veriler hakkında daha fazla öğrenmektedir. Ağın diğer tarafında çıkış birimleri bulunmaktadır, çıkış birimleri ağın kendisine verilen verilere yanıt verdiği yerdir.



**Şekil 4.1.** Örnek yapay sinir ağı

Bilme işleminin nasıl gerçekleştiğine dair araştırma yapan sinir bilimciler insan beyni hakkında birçok bilgi edinmişlerdir. Öğrendikleri şeylerden biri, beynin farklı bölümlerinin bilginin farklı yönlerini işlemekten sorumlu olduğudur. Girdiler beyne girmekte ve her bir nöron seviyesi girdiler hakkında öngörü sağlamaktadır, daha sonra bilgi bir üst seviyeye aktarılmaktadır. YSA'nın insan beyninden ilham aldığı çalışma mekanizması tam olarak budur.

#### 4.4. Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağlarının karakteristik özellikleri uygulanan ağ modeline göre değişmektedir. Bütün modeller için geçerli olan karakteristik özellikler aşağıdaki gibi sıralanabilir [41].

- Yapay sinir ağları makine öğrenmesi gerçekleştirirler: Yapay sinir ağlarının temel işlevi bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar.
- Programları çalışma stili bilinen programlama yöntemlerine benzememektedir.
- Yapay sinir ağları örnekleri kullanarak öğrenirler
- Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir.



- Görülmemiş örnekler hakkında bilgi üretebilirler. Ağ kendisine gösterilen örneklerden genelleme yaparak görmediği örnekler hakkında bilgi üretir.
- Yapay sinir ağlarında bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Diğer programlarda olduğu gibi veriler bir veri tabanında veya programın içinde gömülü değildir. Bilgiler ağın üzerinde saklı olup ortaya çıkartılması ve yorumlanması zordur.
- Şekil (örüntü) ilişkilendirme ve sınıflandırma yapabilirler.
- Örüntü tamamlama gerçekleştirebilirler: Bazı durumlarda ağa eksik bilgileri içeren bir örüntü veya şekil verilir. Ağın bu eksik bilgileri bulması istenir. Örneğin yırtık bir resmin kime ait olduğunun belirlemesi ve tam resmi vermesi gibi bir sorumluluk ağdan istenebilmektedir.
- Kendi kendini organize etme ve öğrenebilme yetenekleri vardır.
- Eksik bilgi ile çalışabilmektedirler: Yapay sinir ağları kendileri eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilirler.
- Hata toleransına sahiptirler: Bir sinir ağı, fonksiyonlarını toplu olarak yerine getirmek için yapay sinir hücrelerine ihtiyaç duymaktadır. YSA hata toleransı özelliği sayesinde bazı hücrelerin çalışmaması halinde bile, genel fonksiyonlarını hala yerine getirebilmeleridir. Ağın çalışmayan hücrelerinin önemine göre ağın performansında düşüşler olabilmektedir. Bu ağın sağlamlığına olan güveni değiştirmese de böyle bir toleransın olduğu ispatlanmıştır.
- Belirsiz, tam olmayan bilgileri işleyebilmektedirler.
- Dereceli bozulma (Graceful degradation) gösterirler: Tahrip edilmiş birimlerin sayısı arttıkça, ağın performansında aniden bozulma olmayıp dereceli bir biçimde performansı düşer.

#### 4.4. Yapay Sinir Ağlarının Dezavantajları

Yapay sinir ağlarının yukarıda bahsedilen avantajlarının yanında dezavantajlarını da aşağıdaki gibi özetlemek mümkündür:

- *Kara Kutu Doğası ( Açıklanamayan ağ davranışı )*: Sinir ağlarının en çok bilinen dezavantajı “kara kutu” doğasıdır. Ağın neden ve nasıl çalıştığı tam olarak bilinemez.
- *Veri Miktarı*: Yapay sinir ağları geleneksel makine öğrenimi algoritmalarından çok daha fazla veri gerektirir. Bu başa çıkılması çok kolay bir sorun değildir. Az miktarda veri bulunan bir veri setiyle çalışırken sinir ağının başarı gösterdiği zamanlar olsa da çoğu zaman performansı düşük olabilmektedir.
- *Ağ yapısını belirlemenin zorluğu*: En iyi performansı elde etmek için probleme uygun bir ağ yapısı oluşturulmalıdır. Katman sayısından her katmandaki düğüm sayısına kadar verilmesi gereken birçok karar vardır. Bu kararları vermek için belirli bir yöntem bulunmamaktadır. En iyi performansı almak için deneme yanılma yoluyla ağ yapısı belirlenir.
- *Eğitim süresinin bilinmemesi*: Ağın eğitiminin ne zaman biteceğini anlamak için bir yöntem bulunmamaktadır. Performans ve hata değerlerinin en aza indirildiği durumda ağın eğitimi tamamlanmış olarak düşünülür.
- *Donanım bağımlılığı*: Yapay sinir ağları, mevcut yapılarından dolayı paralel işlem gücüne sahip işlemciler gerektirir. Paralel işlemleri seri makinelerde yapmak oldukça yavaş gerçekleşmektedir. Seri şekilde çalışan makinelerin sayısı da oldukça çoktur. Burada oluşan zaman kaybı önemli bir dezavantajdır.

Ancak yukarıda sayılan dezavantajlar yapay sinir ağlarına olan ilgiyi azaltmamıştır. Yapay sinir ağlarının karmaşık problemleri çözmesindeki üstünlüğü ve farklı alanlarda gösterdiği başarılı performanslar bilinmektedir. Yapay sinir ağları ile çalışanlar bu dezavantajları başarıya giden yolda karşılaştıkları zorluklar olarak düşünmelidirler.

#### 4.5. Yapay Sinir Ağlarıyla Neler Yapılabilir

YSA bazı mükemmel özelliklerinden dolayı güncel hayatta birçok uygulamada kullanılmaktadır. YSA kullanılarak yapılan çalışmalarının çoğu aşağıdaki üç kategoriyle ilgili olmaktadır:

- Örüntü sınıflandırması
- Tahmin ve finansal analiz

- Kontrol ve optimizasyon

1. Görüntü işleme ve karakter tanıma: YSA'nın çok sayıda girdi alma kabiliyeti göz önüne alındığında, karmaşık ve doğrusal olmayan ilişkileri çözmelerinin yanı sıra, görüntü ve karakter tanıma büyük rol oynamaktadır. El yazısı gibi karakterleri tanımakta, sahtekârlık tespitinde (örneğin banka sahtekârlığı) ve hatta ulusal güvenlik değerlendirmelerinde birçok uygulaması vardır. Görüntü tanıma, sosyal medyada yüz tanıma, tarım ve savunma sanayide uydu görüntü işleme gibi yaygın uygulamalara sahip, sürekli büyüyen bir alandır.

2. Tahmin: Günlük iş kararlarında ( satış tahmini, fiyat tahmini), ekonomi ve para politikalarında, finans ve borsada YSA'nın tahmin gücünden faydalanılmaktadır. YSA ile zaman serisi problemlerinde, veri setinden bir tahmin modeli oluşturulup gelecek ile ilgili tahminler yapılabilir. Bu tarz tahminler oldukça karmaşıktır. Örneğin hisse senedi fiyatlarının tahmin edilmesi bilinen ve bilinmeyen birçok faktöre bağlıdır. Geleneksel tahmin modelleri, bu karmaşık, doğrusal olmayan ilişkileri hesaba katmak için sınırlamalar getirirler. Ancak doğru şekilde uygulanan YSA' lar, görünmeyen özellikleri ve ilişkileri modelleme ve çıkarma kabiliyetinden ötürü rahatlıkla kullanılabilir. Ayrıca geleneksel modellerden farklı olarak YSA girdileri kullanmada herhangi bir kısıtlama getirmez.

3. Optimizasyon problemleri: Optimizasyon problemleri çoğu zaman belirli amaç fonksiyonların minimize edilmesini veya maksimize edilmesini sağlayan optimizasyon yöntemlerinin kullanılmasını gerektirir. Bazen, optimize edilmesi gereken problemler doğrusal değildir; tam olarak çözülemezler ama yaklaşık olarak en iyi sonuca ulaştırırlar.

Gezgin satıcı problemleri ve atama problemleri bunlara örnektir. Genetik algoritma gibi, bir sinir ağı algoritması problemi çözmek için ağın rasgele yönlendirilmesiyle başlar. Bu algoritma bir şehri her seferinde rastgele seçer ve en yakın şehri bulur. Böylece, bu işlem birkaç kez devam eder. Her yinelemeden sonra, ağın şekli değişir ve ağ tüm şehirlerin etrafındaki bir halkaya yaklaşır. Kullanılan algoritma halkaların uzunluğunu en aza indirir. Bu şekilde gezgin satıcı problemi çözülmüş olunur [43] .

Yukarıda anlatıldığı gibi hem günlük hayatta hem de teorik uygulamalarda YSA sıklıkla kullanılmaktadır. Bunların haricinde YSA'nın sıkça kullanıldığı yerlerden bazıları aşağıdaki gibidir [44].

- Çevrim içi alışverişlerde müşterilere uyumlu tavsiyeler vererek daha fazla satış yapılmasını sağlar. E-ticaret devleri birbiriyle uyumlu ürünleri YSA'ya öğreterek daha fazla kar sağlamak için kullanmaktadır. E-ticaret siteleri, kullanıcıların yapmış olduğu aramalarda en fazla ilgili olan ürünleri zaman kaybetmeden kullanıcıya sunmaktadır. Müşterilere görüntüledikleri ürününün yanında aynı ürünü arayan müşterilerin baktığı diğer ürünleri de göstererek öneriler sunmaktadır. Bütün bunları yaparken YSA'nın öğrenme özelliğinden faydalanmaktadırlar.
- Cep telefonlarında sesleri metine dönüştürmek için yine YSA kullanılmaktadır. Kullandığımız telefonlar basitçe bir düğmeye basmak ve bir cümleyi söylemek suretiyle sesleri metinlere dönüştürürler.
- Tıp alanında hastalık ilerlemesinin öngörülmesi, sonuçlarının araştırılması tıbbi bilgilerin çıkartılarak uygun tedavinin planlanmasında YSA kullanılmaktadır.

YSA ile ele alınabilecek problemlerin kapsamı hakkında genel bir bakış açısı vermek için aşağıdaki özet liste kullanılabilir:

**Çizelge 4.1.** YSA'nın kullanıldığı bazı alanlar [45]

<b>MALİ</b>	<b>BİLİM</b>
Borsa tahmini	Örüntü tanıma
Kredi derecelendirme	Kimyasal formülasyon optimizasyonu
İflas tahmini	Kimyasal bileşik tanımlama
Gayrimenkul değerlendirme	Fiziksel sistem modellemesi
Dolandırıcılık tespiti	Ekosistem değerlendirmesi
Fiyat tahminleri	Polimer tanımlama
Ekonomik gösterge tahminleri	Gen tanıma
<b>SANAYİ</b>	Botanik Sınıflandırma
Proses kontrolü	Sinyal İşleme: Yapay Sinir Filtresi
Kalite kontrolü	Biyolojik Sistem Analizi
Sıcaklık ve kuvvet tahmini	<b>SATIŞ VE PAZARLAMA</b>
<b>ENERJİ</b>	Satış tahmini
Elektrik yükü tahmini	Hedef kitle pazarlaması
Enerji talebi tahmini	Perakende satış kar tahmini
Kısa ve uzun vadeli yük tahmini	<b>VERİ MADENCİLİĞİ</b>
Tahmin gaz / kömür endeksi fiyatları	Tahmin
Güç kontrol sistemleri	Sınıflandırma
Hidro baraj izleme	Değişim ve sapma tespiti
<b>İK YÖNETİMİ</b>	Bilgi keşfi
Çalışan seçimi ve işe alma	Zaman serileri analizi
Çalışanların görevlendirilmesi	<b>TIP</b>
Personel planlaması	Tıbbi tanı
Personel profillemesi	Hastanın tedavi süresi tahmini
	Tedavi maliyeti tahmini

#### 4.6. Yapay Sinir Ağlarının Tarihçesi

Tüm bilim dallarında olduğu gibi, sinir ağlarının da inişli çıkışlı olarak seyir göstermiş uzun bir gelişim tarihi vardır.

Sinir ağlarının tarihi, programlanabilir ve elektronik bilgisayarların tarihi ile neredeyse aynı zamanlarda, 1940'lı yılların başlarında başlamıştır. YSA'nın gelişim kronolojik olarak dört devir halinde aşağıdaki gibidir [46] :

#### 4.6.1. Başlangıç Çalışmaları

Warren McCulloch ve Walter Pitts, nörolojik ağların modellerini tanıtmışlar ve bu tür basit ağların bile neredeyse her türlü mantık ya da aritmetik işlevi hesaplayabildiklerini göstermişlerdir.

**1947:** Walter Pitts ve Warren McCulloch (1943'ten itibaren çalışmalarında bahsedilmeyen) pratik bir uygulama alanı, yüzeysel modellerin sinir ağları tarafından tanınmasını sağlamışlardır.

**1949:** Donald O. Hebb, neredeyse tüm sinir öğrenme kurallarının temelini temsil eden klasik öğrenme kuralını formüle etti. "Hebbian öğrenme" denilen bu kural, her iki nöron aynı anda aktif olduğunda iki nöron arasındaki bağlantının güçlendirildiğini ve güçteki değişimin, öğrenme faaliyeti ile orantılı olduğunu öne sürüyordu. Ancak Hebb nörolojik araştırmaların olmayışı nedeniyle kuralı doğrulayamadı.

**1950:** Nöropsikolog Karl Lashley, beyin bilgi depolamasının dağıtımli bir sistem olarak gerçekleştiği tezini savundu.

#### 4.6.2. Altın Çağ

**1951:** Marvin Minsky, ağırlıklarını otomatik olarak ayarlayabilen nuro-bilgisayar Snark'ı geliştirmiştir. Fakat hiçbir zaman pratik olarak uygulayamamıştır, çünkü bilgisayar yoğun bir şekilde hesaplama yapmaktadır fakat nasıl hesap yaptığı tam olarak açıklanamamıştır.

**1956:** Tanınmış bilim adamları Dartmouth Yaz Araştırma Projesinde bir araya gelmişler ve bir beynin nasıl simüle edileceğini tartışmışlardır. Yapay zekânın ilk destekleyicileri yazılım aracılığıyla simüle etmek isterken, sinir ağlarının destekçileri sistemin en küçük parçalarını (nöronları) taklit ederek sistemin davranışını keşfetmek istemişlerdir.

**1957:** MIT Press' de Frank Rosenblatt, Charles Wightman ve arkadaşları, 20 × 20 piksel görüntü sensörü ile basit sayısalı tanıyan ilk başarılı nuro-bilgisayar olan perceptron (tek katmanlı algılayıcı)'u geliştirmiştir.

**1959:** Frank Rosenblatt, algılayıcının farklı versiyonlarını tanımladı, algılayış yakınsama teoremini formüle etti ve doğruladı. Nöron katmanlarını, eşik anahtarlarını ve bağlantı ağırlıklarını ayarlayan bir öğrenme kuralını tanımlamıştır.

**1960:** Bernard Widrow ve Marcian E. Hoff ADALINE (ADaptive LInear NEuron) modelini tanıtmışlardır. Bu model hızlı ve kesin bir öğrenme sağlayan ticari hayatta ve mühendislik uygulamalarında kullanılan ilk sinir ağıdır.

**1961:** Karl Steinbuch, günümüzün sinirsel birleştiricinin öncülleri olarak görülebilen ilişki bellegen tekniğini tanıttı. Ek olarak, sinir teknikleri için kavramları tanımlamış ve olasılıklarını ve sınırlarını analiz etmiştir.

**1965:** "Öğrenme Makineleri" kitabında Nils Nilsson, sinir ağı araştırmalarında kaydedilen ilerlemeler ve üretilen eserler hakkında genel bilgiler verdi. Bu dönemde kendi kendine öğrenmenin temel ilkelerinin ve dolayısıyla genel olarak konuşulan "akıllı" zaten keşfedildiği varsayılmıştır

**1969:** Marvin Minsky ve Seymour Papert tek katmanlı algılayıcıların birçok önemli problemi çözemediğini göstermişlerdir. Bu on beş yıl boyunca yapılan araştırmalarda düşüşe yol açmıştır.

#### **4.6.3. Uzun Sessizlik Ve Yeniden Yapılanma**

**1973:** Christoph Von Der Malsburg doğrusal olmayan ve biyolojik olarak daha gelişmiş bir nöron modeli kullandı.

**1974:** Paul Werbos, hatanın geri yayılması denilen bir öğrenme prosedürü (çok katmanlı algılayıcı) geliştirdi.

**1976-1980:** Stephen Grossberg daha önce öğrenilmiş olan ilişkileri bozmadan, bir sinir ağını öğrenme yeteneğine sahip tutma problemi üzerinde çalıştı. Ayrıca Gail Carpenter işbirliğinde ART (Adaptive Resonance Theory) modelinin gelişmesine yol açtı.

**1982:** Teuvo Kohonen tarafından Kohonen öğrenmesi ve SOM (Self Organizing Map) modelinin geliştirildi.(Danışmansız öğrenme)

Ayrıca John Hopfield fizikteki manyetizma yasalarından esinlenen Hopfield ağlarını da icat etti.

**1983:** Fukushima, Miyake ve Ito, el yazısı karakterleri tanıyan ve 1975'te geliştirilen Cognitron ağının bir uzantısı olan Neocognitron'un sinir modelini tanıtmışlardır.

#### **4.6.4. Rönesans**

Rumelhart, Hinton ve Williams tarafından yapılan geri yayılımın yayılmasıyla, sinir ağları alanı yavaşça yükselme belirtileri gösterdi.

**1985:** John Hopfield, Hopfield ağlarını kullanarak gezgin gezgin satıcı problemine kabul edilebilir çözümler bulma yolunu açıklayan bir makale yayınlamıştır.

**1986:** Delta kuralının bir genellemesi olarak hata öğrenme prosedürünün geri yayılması, paralel dağıtılmış işleme grubu tarafından ayrı ayrı geliştirildi Bu çalışma yapay zekâ alanındaki, o güne kadar olan başarısızlıklardan dolayı ortaya çıkan umutsuzluğa ve yorgunluğa son vermiştir.

Bu tarihten itibaren, araştırma alanının gelişimi son derece hızlı olmuştur. YSA kullanılarak birçok çalışma ve uygulamalar geliştirilmiştir.

### **4.7. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları**

Yapay sinir ağları biyolojik sinir hücresinden ilham alınarak geliştirilmiştir. Bu yüzden yapay sinir ağlarının yapısı ve bileşenlerinden bahsetmeden önce beyin fonksiyonlarının nasıl geliştiğinden ve beynin yapay sinir ağlarına ilham veren özelliklerinden bahsetmek yerinde olacaktır.


#### **4.7.1. Biyolojik Sinir Hücreleri (Nöronlar)**

İnsan beyni herhangi bir geleneksel bilgisayardan çok daha hızlı bir şekilde birçok görevi yerine getirebilir. Bu biyolojik sinir ağlarının büyük ölçüde paralel işleyen bir



yapıya sahip olmasından kaynaklanmaktadır. Yapay sinir ağıları biyolojik sinir ağlarının bu yapısından ilham alınarak geliştirilmiştir. YSA ile bu yeteneğin bilgisayarlara aktarılması hedeflenmiştir.

Beyin, nöron adı verilen çok sayıda (yaklaşık  $10^{11}$ ) bağlantılı elmandan oluşur. Nöronlar birbirleri ile bağlanarak fonksiyonlarını yerine getirirler. Nöronlar *dendritler*, *hücre gövdesi* ve *akson*'lardan oluşmaktadır. Dendritler, elektrik sinyallerini hücre gövdesine taşıyan ağaç benzeri alıcı sinir ağılarıdır. Hücre gövdesi bu gelen sinyalleri etkili bir şekilde toplamaktadır. Akson ise sinyali hücre gövdesinden diğer sinir hücrelerine taşıyan uzun bir yapıdır. Bir hücrenin aksonu ile başka bir hücrenin dendriti arasındaki bağlantı noktasına sinaps adı verilir. Nöronların dizilimini ve sinir ağının işlevini belirlemek sinapsların işidir, sinapslar bir hücreden diğerine elektrik sinyalinin geçmesini sağlarlar. Şekil 4.2, iki biyolojik nöronun basitleştirilmiş bir şematik diyagramını göstermektedir.

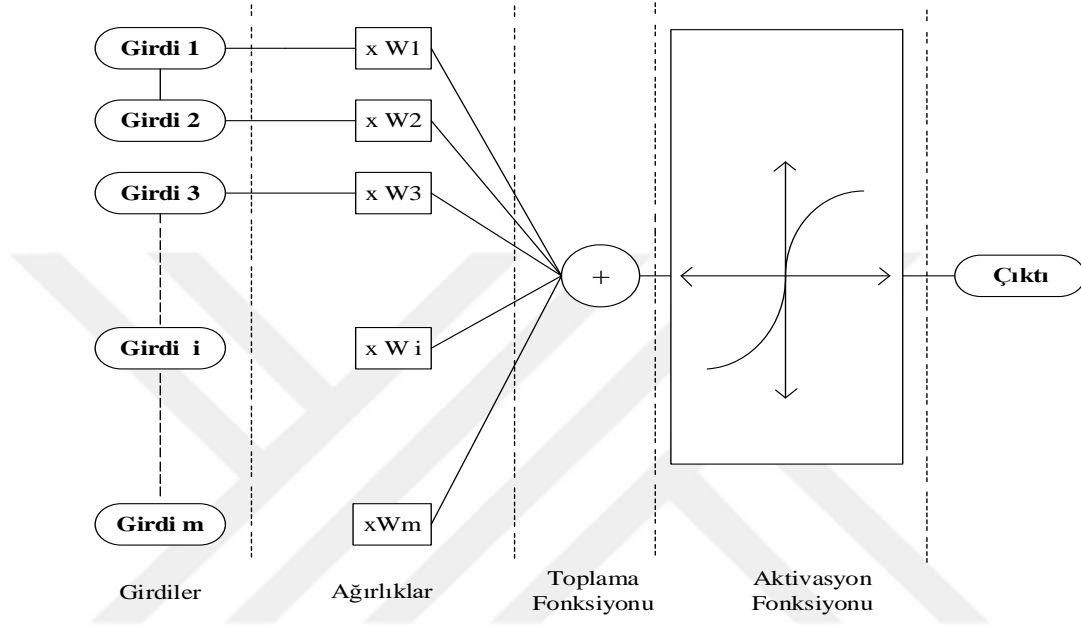


**Şekil 4.2.** İki biyolojik sinir hücresinin bağlantısı

Yapay sinir ağları beynin yapısı kadar karmaşık değildir. Bununla birlikte biyolojik ve yapay sinir ağları arasında iki temel benzerlik vardır. Birincisi, her iki ağın da yapı taşları, oldukça fazla birbirine bağlı olan basit yapay hesaplama cihazlarıdır. İkincisi, nöronlar arasındaki bağlantılar ağın fonksiyonunu belirlemektedir.

#### 4.7.2. Yapay Sinir Hücresi

Biyolojik sinir ağlarını oluşturan sinir hücreleri, yapay sinir ağlarında yapay sinir hücreleri olarak kendini göstermektedir. Yapay sinir hücresinin beş temel elemanı bulunmaktadır.



Şekil 4.3. Yapay sinir hücresinin yapısı

Bir yapay sinir hücresindeki temel elemanların işlevleri aşağıda anlatılmıştır.

##### 4.7.2.1. Girdiler

Yapay sinir hücresine dış dünyadan gelen bilgiler ağırlıklı girdileridir. Bilgiler dış dünyadan veya başka hücrelerden de gelebilir.

#### 4.7.2.2. Ağırlıklar

YSA' da yapay sinir hücreleri arasındaki bağlantılar ağırlık olarak adlandırılmaktadır. Biyolojik sinir hücresinde meydana gelen çoklu işlemler, yapay sinir hücresinde ağırlık olarak atanan sayılarla gerçekleşmektedir. Ağırlığın büyüklüğüne göre yapay hücreye gelen bilginin önem seviyesi değişmektedir. Veriler sinir ağını beslerken, ağırlıklar değişmekte ve sinir ağı bu şekilde öğrenmektedir. Ağırlıklar hiç değişmeyip, önceden belirlenen sabit değerler de olabilir.

#### 4.7.2.3. Toplama Fonksiyonu

Toplama fonksiyonu hücreye gelen girdileri birleştirerek net girdiyi hesaplamaktadır. YSA ile yapılan çalışmalarda toplama fonksiyonu olarak birçok fonksiyon kullanılabilir. En yaygın kullanılan toplama fonksiyonu ağırlıklı toplama fonksiyonudur. Bu fonksiyon net girdiyi hesaplarken yapay sinir hücresine gelen girdilerin her birini kendi ağırlıklarıyla çarparak sonuçları toplamaktadır. Formülasyonu denklem (4.1)' de gösterilmektedir.

$$NET = \sum_i^n G_i A_i \quad (4.1)$$

Eşitlik 4.1'de,

G: Girdi değerlerini

A: Ağırlıkları

n: Toplam girdi sayısını ifade etmektedir.

#### 4.7.2.4. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu gelen girdileri işleyerek bir sinir ağına çıkışı belirleyen matematiksel denklemlerdir. Her bir veri için binlerce hatta milyonlarca sinir hücresinde hesaplama yaptıkları için hesaplama açısından verimli olması gerekmektedir. Ağırlık karmaşık verileri öğrenmesine ve doğru tahminler yapmasına


yardımcı olan doğrusal olmayan birçok aktivasyon fonksiyonu bulunmaktadır. Üzerinde çalışılan problem için en uygun fonksiyonu belirleyecek sabit bir yöntem yoktur. Modeli tasarlayanın denemeleri sonucunda en uygun fonksiyon belirlenmektedir.

Ayrıca aktivasyon fonksiyonları her bir yapay sinir hücresinin çıkışını 1 ile 0 arasında veya -1 ile 1 arasında bir değere normalleştirmeye yardımcı olur. Aktivasyon fonksiyonu transfer fonksiyonu olarak da adlandırılmaktadır.

YSA ile yapılan çalışmalarda en çok kullanılan aktivasyon fonksiyonu sigmoid fonksiyonudur. Sigmoid fonksiyonunun formülasyonu aşağıdaki gibidir:

$$F(\text{NET}) = \frac{1}{1+e^{-\text{NET}}} \quad (4.2)$$

Formülasyonlardaki NET ifadesi toplama fonksiyonlarında hesaplanmış olan girdi değerleridir.



**Şekil 4.4.** Sigmoid fonksiyonu

Sigmoid fonksiyonunun şekli Şekil 4.4'te gösterilmiştir. Diğer aktivasyon fonksiyonları Çizelge 4.2'deki gibidir.

**Çizelge 4.2.** Aktivasyon fonksiyonu örnekleri [41]

<b>Aktivasyon fonksiyonu</b>	<b>Açıklama</b>
Lineer fonksiyon $F(\text{NET}) = \text{NET}$	Gelen girdiler olduğu gibi hücrenin çıktısı olarak kabul edilir.
Step fonksiyonu $F(\text{NET}) = \begin{cases} 1 & \text{if } \text{NET} > \text{eşik\_değer} \\ 0 & \text{if } \text{NET} \leq \text{eşik\_değer} \end{cases}$	Gelen NET girdi değerinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerlerini alır.
Sinus fonksiyonu $F(\text{NET}) = \text{Sin}(\text{NET})$	Öğrenilmesi düşünülen olayların sinus fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.
Eşik değer fonksiyonu $F(\text{NET}) = \begin{cases} 0 & \text{if } \text{NET} \leq 0 \\ \text{NET} & \text{if } 0 < \text{NET} < 1 \\ 1 & \text{if } \text{NET} \geq 1 \end{cases}$	Gelen bilgilerin 0 veya 1'den büyük ya da küçük olmasına göre değerler alır. 0 ve 1 arasında değerler alabilir. Bunların dışında değerler alamaz.
Hiperbolik tanjant fonksiyonu $F(\text{NET}) = (e^{\text{NET}} + e^{-\text{NET}}) / (e^{\text{NET}} - e^{-\text{NET}})$	Gelen NET girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanır.

#### 4.7.2.5. Hücre Çıktısı

Aktivasyon fonksiyonunun yaptığı işlemler sonucu belirlenen çıktı değeridir. Bir yapay sinir hücresinde birden fazla girdi olsa da tek bir çıktı değeri vardır.

### 4.8. Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağlarını sınıflandırırken katman sayısına, bağlantı yapısına ve öğrenme stratejisine göre ayrı ayrı başlıklar altında anlatmak geniş bir çerçeveden bakmayı sağlayabilir. Böylelikle parçaları birleştirmek ve anlamak daha kolay olacaktır.

#### 4.8.1. Katman Sayısına Göre Sınıflandırma

Yapay sinir ağları tek katmanlı ve çok katmanlı olarak ikiye ayrılmaktadır.

#### 4.8.1.1. Tek Katmanlı Yapay Sinir Ağları

İlk yapay sinir ağı çalışmaları ve geliştirilen ilk modeller tek katmanlı YSA ile yapılmıştır. Tek katmanlı YSA sadece girdi ve çıktı katmanlarından oluşmaktadır. Doğrusal problemlerin çözümünde kullanılmış, doğrusal olmayan problemlerin çözümünde başarısız kalmıştır. Tek katmanlı yapay sinir ağları modellerinin en önemlileri Basit Algılayıcı Modeli ( Perseptron), Adaptif Doğrusal Eleman (Adaptive Linear Element - ADALINE), Çoklu Adaptif Doğrusal Eleman (Multiple Adaptive Linear Element -MADALINE)'dir.

#### 4.8.1.2. Çok Katmanlı Yapay Sinir Ağları

Çok katmanlı sinir ağları birden fazla düğüm katmanı içermekte ve doğrusal olmayan olayları çözebilmektedir. Bir başka deyişle ağın öğrenmesi istenen girdi ve çıktılar arasındaki ilişkiler doğrusal olmayan ilişkilirse öğrenme işlemi çok katmanlı yapay sinir ağları ile yapılmaktadır. Günümüzde kullanılan ağların büyük çoğunluğu çok katmanlı bir modele sahiptir [47] .

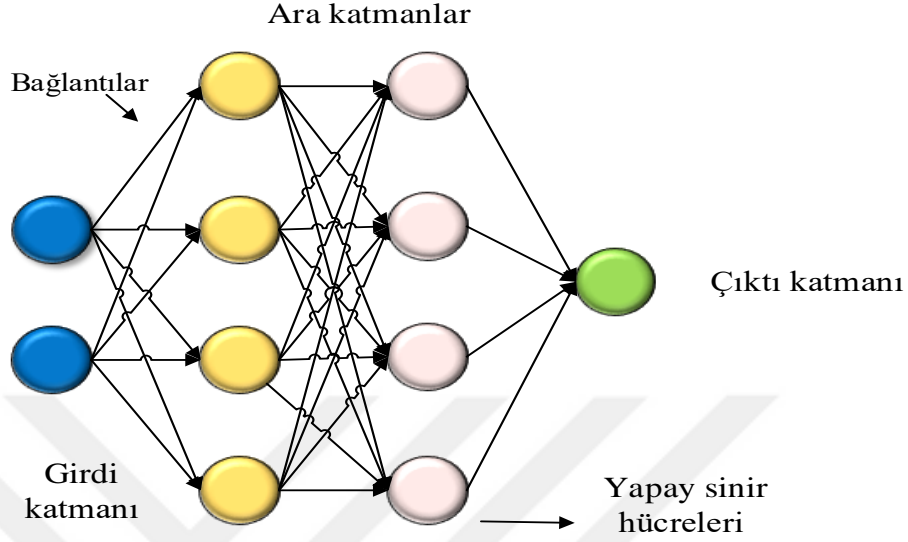
Çok katmanlı ağların eğitilmesi, tek katmanlı ağların eğitilmesine göre oldukça zordur. Buna rağmen birçok problemin çözümünde çok katmanlı ağların eğitimi, tek katmanlı ağların eğitimine göre daha başarılı olabilmektedir. Bunun nedeni, tek katmanlı ağların problemin çözümü için yetersiz kalmalarından kaynaklanmaktadır [8] .

Çok katmanlı ağlarda yapay sinir hücreleri yapay sinir ağlarını oluştururken rasgele bir araya gelmezler. Hücreler genel olarak üç katman halinde ve her katman içinde paralel olarak yerleşerek ağı oluştururlar. Bu katmanlar:

Girdi katmanı: Giriş katmanı yapay sinir ağı için iş akışının başlangıcıdır. Bir sinir ağının giriş katmanı yapay sinir hücrelerinden oluşur ve daha sonraki yapay sinir katmanları tarafından ileri işleme için ilk verileri sisteme getirir.

Ara katmanlar: Ara katmanlar girdi katmanından gelen bilgileri işleyerek bu bilgileri çıktı katmanının kullanabileceği şekle dönüştürürler. Bir ağ birden fazla ara katmandan oluşabilir.

Çıktı katmanı: Yapay sinir ağındaki çıktı katmanı, girdi katmanındaki veri seti için belirli çıktılar üreten son katmandır.



Şekil 4.5. Çok katmanlı bir yapay sinir ağı örneği

Çok katmanlı algılayıcı ağının öğrenme kuralları ve eğitilmesi Bölüm 4.10'da anlatılmıştır.

#### 4.8.2. Bağlantı Yapılarına Göre Sınıflandırma

Yapay sinir ağları, sinir ya da düğüm adı verilen çok sayıdaki işlem elemanının bir araya gelmesinden oluşur. YSA mimarileri, sinirler arasındaki bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönlerine göre birbirlerinden ayrılmaktadır. Buna göre yapay sinir ağları için ileri beslemeli (feedforward) ve geri beslemeli (feedback/recurrent) ağlar olmak iki temel ağ mimarisi vardır [9].

##### 4.8.2.1. İleri Beslemeli Ağlar

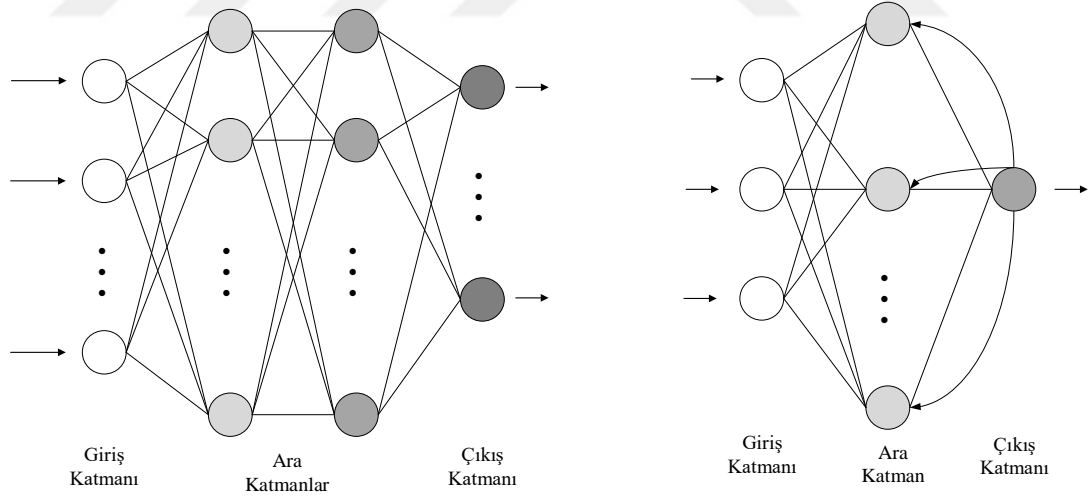
İleri beslemeli ağlar çok katmanlı sinir ağları olarak da bilinmektedir. Hücreler katmanlar halinde düzenlenmiştir ve tek bir koşulu vardır: bilgi girdiden çıktıya doğru

geri dönüşsüz olarak tek bir yönde akmaktadır. Bu ağlar girdileri çıktılarla ilişkilendirirler, sabit giriş ve çıkışlara sahiptirler. İleri beslemeli ağlar çoğunlukla örüntü oluşturma, örüntü tanıma ve sınıflandırmada kullanılmaktadır.

#### 4.8.2.2. Geri Beslemeli Ağlar

Geri beslemeli sinir ağlarında sinyaller her iki yönde de gidebilir. Bu tür ağlarda geri besleme döngülerine izin verilmektedir.

Çıkış katmanından giriş katmanına veya gizli katmandan giriş katmanına besleme bağlantılarıyla geri beslemeler yapılabilir. Başka bir deyişle, bir geri besleme mimarisi en az bir geri besleme bağlantısına sahip olması nedeniyle kendisini ileri beslemeli bir mimariden ayırır. Bu yapısı ile geri beslemeli YSA, doğrusal olmayan dinamik bir davranış gösterir. Özellikle zaman serileri ve tahmin çalışmalarında iyi sonuçlar vermektedir. Çok katmanlı ileri beslemeli ağ yapısı ve geri beslemeli ağ yapısı Şekil 4.6'da gösterilmiştir.



Şekil 4.6. İleri ve geri beslemeli ağ yapıları



### 4.8.3. Öğrenme Stratejilerine Göre Sınıflandırma

Önceki bölümlerde bahsedildiği gibi YSA'nın ilk modellerinin doğrusal olan problemlere çözüm getirirken doğrusal olmayan ilişkileri öğrenmede yetersiz kalmasından dolayı doğrusal olmayan ilişkileri öğrenebilmek için çok katmanlı algılayıcılar geliştirilmiştir. Çok katmanlı algılayıcılar öğrenme stratejilerine göre danışmalı öğrenme (supervised learning), danışmansız öğrenme (unsupervised learning) ve destekleyici öğrenme (reinforcement learning) olmak üzere üç başlık altında anlatılabilir.

#### 4.8.3.1. Danışmanlı Öğrenme

Danışmanlı öğrenmede ağın eğitimi için bir öğretmen yardımcı olmaktadır. Öğretmen ağa, öğrenilmesi istenen olayla ilgili örnek girdi değerlerinden ve hedef(gerçek) çıktı değerlerinden oluşan bir veri seti verir. Ağ verilen girdileri işleyerek kendi çıktısını üretir. Üretilen çıktı gerçek çıktı ile karşılaştırılarak hata (sapma) oranı tespit edilir. Buradaki hata gerçekleşen çıktı ile ağın öğrenmesi sonucunda oluşan çıktı arasındaki farktır. Bu hatayı en aza indirmek için bağlantıların ağırlıkları yeniden düzenlenir. Bu işlem hata seviyesi en uygun seviyeye inene kadar sürer. Hata değeri istenilen düzeye geldiğinde eğitim işlemi bitmiş olur ve tüm ağırlıklar sabitlenir.

Danışmanlı öğrenmede algoritmalarında genellikle hata oranlarının hesaplanması için Ortalama Mutlak Hata (MAE: Mean Absolute Error) ve Hata Kareleri Ortalamasının Karekökü (MSE: Mean Square Error) performans ölçütleri olarak kullanılır. Delta kuralı danışmanlı öğrenme algoritmalarına örnek olarak verilebilir.

#### 4.8.3.2. Danışmansız Öğrenme

Danışmansız öğrenmede danışmanlı öğrenmeden farklı olarak hedef çıktı değerleri ağa sunulmamaktadır. Ağ yalnızca girdi verileri sunulmaktadır. Bu nedenle ağın ürettiği çıktıları kontrol eden ve gerçek çıktılarla karşılaştıran bir danışman bulunmamaktadır. Sistem girdiler arasındaki ilişkileri kendi kendine öğrenmekte ve bu bilgilere göre ağırlık değerlerini kendisi ayarlamaktadır. Hebb, Hopfield ve Kahonen öğrenme kuralları danışmansız öğrenmeye örnektir.

#### 4.8.3.4. Destekleyici Öğrenme

Destekleyici öğrenme sisteme yardımcı olan bir danışman olduğu için denetimli öğrenmeye benzetilmektedir. Ancak danışman girdi ve çıktı setini sisteme öğretmek yerine, üretilen çıktının doğru ya da yanlış olduğunu gösteren bir sinyal üretir. Sistem danışmandan aldığı bu sinyalleri dikkate alarak öğrenmeye devam eder. Doğrusal vektör parçalama modeli diye isimlendirilen LVQ (Linear Vektör Quantization) destekleyici öğrenmeyi kullanan modellere örnek olarak gösterilebilir [41].

#### 4.9. Yapay Sinir Ağlarının Eğitimi ve Öğrenme Kuralları

YSA' da hücre elemanlarının bağlantılarının ağırlık değerlerinin belirlenmesi işlemine "ağın eğitilmesi" denir. Başlangıçta bu ağırlık değerleri rastgele alınır. YSA kendine örnekler gösterildikçe bu ağırlık değerlerini yenileyerek amaca ulaşmaya çalışır. Ağırlıkların sürekli yenilenip istenilen sonuca ulaşana kadar kadar geçen zamana "öğrenme" denir. Ağırlık değerlerinin değişmesi belirli kurallara göre yürütülmektedir. Bu kurallara "öğrenme kuralları" denir. YSA' da eğitim süreci veri setinin rastgele seçimle 3 alt veri setinin oluşturulmasıyla başlar. Bu veri setleri eğitim, doğrulama ve test verilerini içermelidir. Genellikle veri örneklerinin %50–70 arası eğitim setinde, %50–30 arası doğrulama ve test setinde yer alır. Doğrulama ve test setine de verilerin rastgele ve eşit oranlarda dağıtılmasına dikkat edilir. Ağ ağırlıklarının güncellenmesi ve nihai değerlerinin kestirimi eğitim aşamasında gerçekleşir. Eğitim sürecinin ne zaman sonlandıracağına karar vermek ezberleme probleminin önüne geçmek ve en etkili modeli oluşturmak için önemlidir. Ağırlıkların sürekli yenilenmesi ağın öğrenmeye çalıştığı olayla ilgili genelleme yapabilecek düzeye ulaşmasıyla yani en doğru ağırlık değerlerine ulaşmasıyla son bulur.

##### 4.9.1. Öğrenme Kuralları

Yapay sinir ağı öğrenirken yukarıda anlatılan öğrenme stratejilerinden hangisi kullanılırsa kullanılsın belirli kurallara göre öğrenmektedir. Bu kurallara öğrenme kuralları denir. Öğrenme kuralı veya öğrenme süreci bir yöntem veya matematiksel bir mantıktır. Geliştirilen bu kurallar bir sinir ağının mevcut koşullardan öğrenmesine ve

performansını iyileştirmesine yardımcı olur. Öğrenme kuralları çevrimiçi(on -line) ve çevrimdışı (off-line) olarak çalışmaktadır.

#### 4.9.1.1. Çevrimiçi Öğrenme Kuralları

Bu kurallar gerçek zamanlı çalışabilmektedirler. Bu kurallara göre öğrenen sistemler gerçek zamanda çalışırken bir taraftan fonksiyonlarını yerine getirmekte diğer taraftan ise öğrenmeye devam etmektedir. Kohonen öğrenme kuralı, bu sınıfa örnek olarak verilebilir [41] .

**1.Kohonen öğrenme kuralı:** Bu kuralda sinir hücreleri ağırlıkları değiştirmek için birbirleri ile yarışır. En büyük çıktıyı üreten hücre kazanan hücre olur ve bağlantı ağırlıklarını değiştirir. Kazanan hücre, yakınındaki hücelere göre daha kuvvetli hale gelmektedir [41].

**2.Art ağının öğrenme kuralı:** Bu kural Grosberg'in 1976'da biyolojik beynin üzerine yaptığı çalışmalar sonucunda Adaptif Rezonans Teori (ART) ağlarını geliştirmesiyle ortaya çıkmıştır [4] .

Art ağları insan beyninin davranışları ve sinir sistemi hakkında bilinen bulgular üzerine kurulmuşlardır. Beynin kullandığı sezgisel yaklaşımları matematikse bir modele dönüştürmelerinden dolayı art ağları bilim dünyasında son derece önemlidir [41].

Art modeli biyolojik sistemlerin üç temel özelliğinden esinlenmiştir. Bunlar:

**Normalizasyon :** Biyolojik sistemlerin çevredeki büyük değişikliklere karşı adapte olarak çevredeki bu olayları normal görmesi durumudur. Örneğin sesli ortamlarda çalışan kişiler önceleri rahatsız olurken bir süre sonra sesi duymazdan gelip ve sestem etkilenmemektedir.

**Ayrıştırabilme:** İnsanlar karar verirken çevredeki olayların farklarını ayırt ederler ve yorumlarlar. Küçük gibi görünen ayrıntılar hayati bir öneme sahip olabilir. Örneğin sakın bir at ile kızmış bir at vücut dilinden fark edilebilir, atlar kızdıklarında kulaklarını geriye doğru götürürler ve böylelikle insanlar o an için bir şeylerin yolunda gitmediğini anlarlar. Biyolojik sistemlerin bu ayrıntıları fark etmeleri son derece önemli özelliklerindedir.

**Kısa dönemli hafıza:** İnsanlar çevreden öğrendiklerini direk olarak davranışlarına dökmeden önce bir süre hafızasında saklamaktadır. Hafızadaki bütün bilgilerin etkisi

uzun süreli olmasa da sürekli aynı şeyleri tekrar etmek olayların uzun dönemli hafızaya taşınmasına sebep olur.

Grosberg, biyolojik sistemlerin yukarıda sayılan özelliklerinden yola çıkarak Adaptif Rezonans Teorisi (ART) adını verdiği yapay sinir ağlarını oluşturmuştur. Art ağları sınıflandırma problemlerinde iyi öğrenirler ve sıklıkla kullanılmaktadır.

#### 4.9.1.2. Çevrimdışı Öğrenme Kuralları

Çevrimdışı öğrenme kurallarına dayalı öğrenen sistemler kullanıma alınmadan önce örnekler üzerinde eğitilirler. Bu kuralları kullanan sistemler eğitildikten sonra gerçek hayatta kullanıma alındığında artık öğrenme olmamaktadır. Sistemin öğrenmesi gereken yeni bilgiler söz konusu olduğunda sistem kullanımdan çıkarılmakta ve çevrimdışı olarak yeniden eğitilmektedir. Eğitim tamamlanınca sistem tekrar kullanıma alınmaktadır [41] .

**1. Hebb öğrenme kuralı:** Hebb Kuralı 1949 yılında Donald Hebb tarafından geliştirilmiştir. Öğrenme kuralları içinde en eski geliştirilen öğrenme kuralıdır. Tüm öğrenme kurallarının temelini oluşturmaktadır.

Kural özetle şu şekildedir; “Eğer sinyal alan ile gönderen nöronlar arasındaki sinaptik ağırlıkların ikisi de matematiksel olarak aynı işarete sahip ise, bu iki nöron arasındaki bağ kuvvetlendirilmelidir. Aksi halde bağın kuvveti azaltılmalıdır [14] .

**2. Hopfield öğrenme kuralı:** Bu kural Hebb kuralına benzemektedir. Sinir hücrelerinin bağlantılarının ne ölçüde kuvvetlenmesi ya da zayıflatılması gerektiğini belirlemektedir. Verilen girdiler ile alınan çıktıların tutarlılığına göre öğrenme katsayısı kadar ağırlık değerleri artırılır ya da azaltılır. Öğrenme katsayısı genelde 0-1 arasındadır ve kullanıcı tarafından belirlenmektedir.

**3. Delta öğrenme kuralı:** Widrow ve Hoff tarafından geliştirilen delta kuralı, en yaygın öğrenme kurallarından biridir. Bu kural ağın ürettiği çıktı ile gerçekleşen çıktı arasındaki farkı azaltmak için bağlantılardaki ağırlıkların değerlerinin sürekli olarak güncellenmesi ilkesine dayanmaktadır.

#### 4.10. Çok Katmanlı Algılayıcılar (ÇKA)

YSA ile ilgili ilk çalışmalar tek katmanlı algılayıcılar (TKA) ile başlamıştır. Tek katmanlı algılayıcılar problem uzayını bir doğru veya bir düzlem ile sınıflara ayırmaktadır. Problemin girdileri ağırlıklar ile çarpılarak toplanmakta ve sonuçta elde edilen değerlerin bir eşik değerden büyük ya da küçük olma durumuna göre girdilerin sınıfı belirlenmektedir. Sınıflar 1 veya -1 rakamları ile gösterilmektedir. Ağ öğrenirken ağırlıklar ve eşik değer ünitesinin ağırlıkları değiştirilmekte ve ağa sunulan girdilerle çıktılar üretilmektedir.

İlk modellerin en temel problemi öğrenmesi istenen olayların girdi ve çıktıları arasında doğrusal olmayan ilişkiler olduğunda öğrenme gerçekleştirilememesidir. ÇKA bu sorunu çözmek için geliştirilmiştir. Çok katmanlı yapay sinir ağlarının genel yapısından Bölüm 4.8.1.2’de bahsedilmiştir.

Tek katmanlı algılayıcıların doğrusal olmayan olayları öğrenmede yetersiz kalması fikri ilk olarak XOR probleminin çözülmemesiyle ortaya çıkmıştır. XOR probleminde girdi ve çıktıların ilişkisi doğrusal olmadığından çıktıların arasına bir doğru çizerek problem uzayını sınıflara ayırmak mümkün olmamıştır.

**Çizelge 4.3.** XOR problemi

Girdi 1	Girdi 2	Çıktı
0	0	0
0	1	1
1	0	1
1	1	0

XOR problemi tek katmanlı algılayıcı modellerinden olan Basit algılayıcı ve ADALINE modelleri ile çözülemeye çalışılmış fakat sonuç alınamamıştır. Bu sebeple YSA’nın doğrusal olmayan problemlere çözüm üretmediği düşünülmüş ve araştırmalar uzun bir süre durmuştur. Daha sonra Rumelhart, Hinton ve Williams yaptıkları çalışmalar sonucunda XOR problemini çözmek için *çok katmanlı algılayıcı modeli* geliştirmişlerdir. Bu gelişme YSA çalışmalarında yeni bir dönemin

başlamasına neden olmuştur. Bu modele *hata yayma modeli* veya *geri yayım modeli* de denmektedir. Delta öğrenme kuralını kullanan bu modelin temel amacı gerçekleşen çıktı ile ağın ürettiği çıktı arasındaki hatayı en aza indirmektir.

#### 4.10.1. ÇKA Ağının Öğrenme Kuralı


ÇKA ağları danışmanlı öğrenme stratejisine göre çalışırlar. Yani; bu ağlara eğitim sırasında hem girdiler hem de o girdilere karşılık üretilmesi gereken(beklenen) çıktılar gösterilir. Ağın görevi her girdi için o girdiye karşılık gelen çıktıyı üretmektir. ÇKA ağının öğrenme kuralı en küçük kareler yöntemine dayalı genelleştirilmiş delta kuralıdır. Genelleştirilmiş delta kuralı iki safhadan oluşur [41] :

1. İleri Doğru Hesaplama Safhası veya *İleri Besleme (Feedforward)*
2. Geriye Doğru Hesaplama Safhası veya *Geri Yayılma (Backpropagete)*

##### 4.10.1.1. İleri Doğru Hesaplama Safhası

İleriye doğru hesaplama safhasında ağın çıktıları hesaplanır, hesaplama adımları aşağıdaki gibidir:

- 1. Adım:** Eğitim verilerindeki bir örneğin girdi katmanından ağa gönderilir
- 2. Adım:** Gelen girdiler girdi katmanında herhangi bir bilgi işleme/değişiklik yapılmadan ara katmana gönderilir
- 3. Adım:** Girdi katmanından ara katmanlara gelen bilgiler bağlantı ağırlıklarının etkisiyle (bağlantı ağırlıklarıyla çarpılarak) gelmektedir. Ara katmana gelen net girdi bu çarpım değerleri toplanarak bulunur. Ara katman çıktıları hesaplanırken net girdi aktivasyon fonksiyonundan geçirilir. Burada kullanılan aktivasyon fonksiyonu genellikle sigmoid fonksiyonudur fakat türevi alınabilen diğer fonksiyonlar da kullanılabilir
- 4. Adım:** 3. aşamada anlatıldığı gibi net girdilerin hesaplanarak aktivasyon fonksiyonundan geçirilmesiyle ara katmanın bütün proses elemanları ve çıktı katmanının proses elemanlarının çıktıları belirlenmiş olunur. Çıktı katmanından çıkan değerler bulunduğu ağın ileri hesaplama işlemi tamamlanmış demektir.



**Şekil 4.7.** Bir yapay sinir hücresinin(proses elemanı) çalışma örneği

Hücreye gelen NET girdi, ağırlıklı toplam alınarak aşağıdaki şekilde hesaplanır:

$$NET = 0.4 * (-0.1) + 0.7 * 0.3 + 0.3 * 0.2 + 0.2 * (-0.4)$$

$$NET = -0.04 + 0.21 + 0.06 + -0.08$$

$$NET = 0.15$$

Hücresin sigmoid fonksiyonuna göre çıktısı ( Ç ) aşağıdaki gibi hesap edilir:

$$\text{Ç} = 1 / (1 + e^{-0.15})$$

$$\text{Ç} = 0.537$$

#### 4.10.1.2. Geriye Doğru Hesaplama Safhası

Geriye doğru hesaplama safhasında tahmin hatasının azaltılması için ağırlıklar değiştirilmektedir. Adımları aşağıdaki gibidir:

**1. Adım:** Ağa verilen girdiler sonucunda ağın ürettiği çıktılar ( $\text{Ç}_1, \text{Ç}_2, \dots$ ) ile beklenen çıktılar ( $B_1, B_2, \dots$ ) karşılaştırılır. Bunların arasındaki fark(hata) bulunur. Çıktı katmanındaki m. yapay sinir hücresi için oluşan hata ( $E_m$ ) aşağıdaki gibi gösterilebilir.

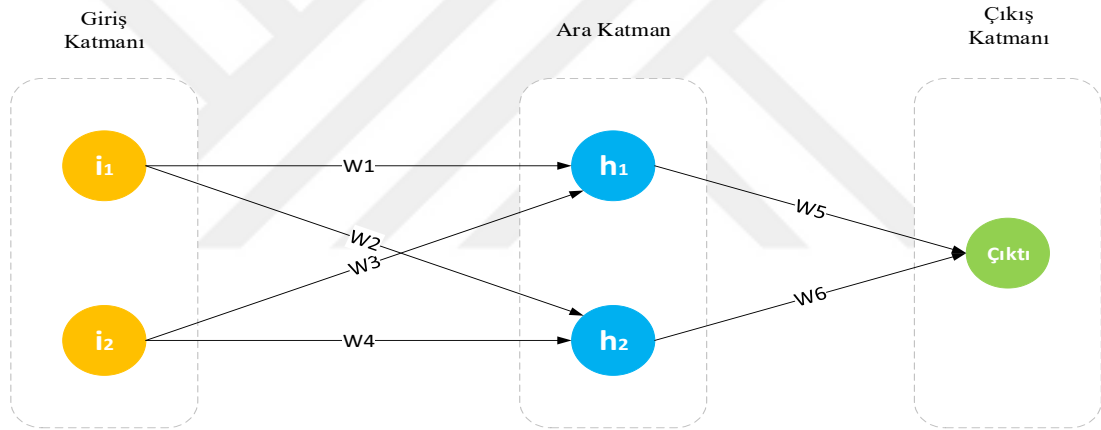
$$E_m = B_m - \text{Ç}_m \quad (4.3)$$

**2. Adım:** Geriye doğru hesaplama ile oluşan hatayı düşürmek hedeflenir ve bunun için hata, ağın ağırlık derecelerine dağıtılarak bir sonraki iterasyonda hatanın azaltılması sağlanır. Bir proses elemanı için oluşan hata ( $E_m$ ) yukarıdaki şekilde bulunduktan sonra çıktı katmanı için oluşan toplam hatayı (TH) bulmak gerekir. Tahmin edilen

çıktıların beklenen çıktılardan büyük olduğu durumlarda hata değerleri negatif geleceğinden toplam hatanın yanlış olmasını önlemek amacıyla ağırlıkların kareleri hesaplanır daha sonra türev hesaplamasını kolaylaştırmak için  $\frac{1}{2}$  ile çarpılır. TH aşağıdaki gibi bulunabilir:

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (4.4)$$

Eğitimin temel hedefi toplam hatayı en düşük seviyeye çekerek daha iyi tahmin değerleri almaktır. Bunun için hatanın, kendisine neden olan proses elemanlarına dağıtılması gerekmektedir. Bunu geri yayılma sağlar, geri yayılma ile proses elemanlarının ağırlıkları değişecektir. Ağırlık değişme işlemlerinin nasıl yürüdüğü aşağıda adım adım anlatılmıştır [48] :



Şekil 4.8. Başlangıç ağırlıklarıyla yapılan tahmin

$[i_1 \ i_2] \cdot \begin{bmatrix} W_1 & W_3 \\ W_2 & W_4 \end{bmatrix} = [h_1 \ h_2] \cdot \begin{bmatrix} W_5 \\ W_6 \end{bmatrix} = [Ç_1]$  başlangıç ağırlıklarıyla hesaplanmış çıktı değeri  $Ç_1$  ' dir.

Ara katman ile çıkış katmanı arasında tahmin edilen çıktı değerleri aşağıdaki şekilde bulunur.

$$h_1 = i_1 W_1 + i_2 W_2 \quad (4.5)$$

$$h_2 = i_1 W_3 + i_2 W_4 \quad (4.6)$$

$$B_m = h_1 W_5 + h_2 W_6 \quad (4.7)$$



$$B_m = (i_1 W_1 + i_2 W_2) W_5 + (i_1 W_3 + i_2 W_4) W_6 \quad (4.8)$$

Geri yayılmada, sinir ağının ağırlıklarına göre hata fonksiyonunun derecesi hesaplanır. Fonksiyonun minimumunu bulmak için “Gradyan İniş” adı verilen yenilemeli bir optimizasyon algoritması kullanılmaktadır. Gradyan inişi kullanan bir fonksiyonun yerel minimumunu bulmak için, geçerli noktada fonksiyonun gradyanının negatifiyle orantılı adımlar atılır.

Aşağıdaki formülde ifade edildiği gibi güncellenecek ağırlık hata fonksiyonunun kısmi türevine göre hesaplanır. Yeni güncellenmiş ağırlığın hata fonksiyonunu en aza indirdiğinden emin olmak için hata fonksiyonunun türevi öğrenme katsayısı ile çarpılmaktadır. Yeni ağırlık bulma formülü aşağıdaki gibidir:

$$*W_x = W_x - a \left( \frac{\partial E_m}{\partial W_x} \right) \quad (4.9)$$

\* $W_x$  : Yeni ağırlıklar

$W_x$  : Eski ağırlıklar

$a$  : Öğrenme katsayısı

$\left( \frac{\partial E_m}{\partial W_x} \right)$  : Ağırlığa göre hatanın türevi

Hata fonksiyonunun türetilmesi aşağıdaki **zincir kuralının** uygulanmasıyla gerçekleşmektedir.

$$\frac{\partial E_m}{\partial W_x} = \frac{\partial E_m}{\partial B_m} * \frac{B_m}{\partial W_x} \quad (4.10)$$

Eşitlik 4.10 zincir kuralıdır.

$$\frac{\partial E_m}{\partial W_x} = \frac{\frac{1}{2}(B_m - \zeta_m)^2}{\partial B_m} * \frac{\partial (i_1 W_1 + i_2 W_2) W_5 + (i_1 W_3 + i_2 W_4) W_6}{\partial W_x} \quad (4.11)$$

$$\frac{\partial E_m}{\partial W_x} = 2 * \frac{1}{2} (B_m - \zeta_m) * \frac{\partial (B_m - \zeta_m)}{\partial B_m} * (i_1 W_3 + i_2 W_4) \quad (4.12)$$

$$\frac{\partial E_m}{\partial W_x} = (B_m - \zeta_m) * h_2 \quad (4.13)$$

$$\Delta = B_m - \zeta_m \quad (4.14)$$

$$\frac{\partial E_m}{\partial W_x} = \Delta h_2 \quad (4.15)$$

Ağırlık güncelleme formülü aşağıdaki gibi olmuş olur.

$$*W_x = W_x - a \Delta h_2 \quad (4.16)$$

Bu şekilde çıktı katmanı ve gizli katman arasındaki diğer ağırlıklar ve ağırlık güncelleme formülleri türetilebilir. Ağırlık güncellemeleri geriye doğru yapılmaktadır. Örneğin giriş katmanı ve ara katman arasında var olan  $W_1$  ağırlığı aşağıdaki gibi güncellenmektedir.

$$\frac{\partial E_m}{\partial W_1} = \frac{\partial E_m}{\partial B_m} * \frac{\partial B_m}{\partial h_1} * \frac{\partial h_1}{\partial W_1} \quad (4.17)$$

$$\frac{\partial E_m}{\partial W_1} = \frac{\partial \frac{1}{2}(B_m - \zeta_m)^2}{\partial B_m} * \frac{\partial (h_1) W_5 + (h_2) W_6}{\partial h_1} * \frac{\partial i_1 W_1 + i_2 W_2}{\partial W_1} \quad (4.18)$$

$$\frac{\partial E_m}{\partial W_1} = 2 * \frac{1}{2} (B_m - \zeta_m) * \frac{\partial (B_m - \zeta_m)}{\partial B_m} * (W_5) * (i_1) \quad (4.19)$$

$$\frac{\partial E_m}{\partial W_1} = (B_m - \zeta_m) * (W_5) * (i_1) \quad (4.20)$$

$$\frac{\partial E_m}{\partial W_1} = \Delta W_5 i_1 \quad (4.21)$$

Özet olarak, tüm ağırlıklar için güncelleme formülleri aşağıdaki gibi olacaktır.

$$*W_6 = W_6 - a (h_2 \cdot \Delta)$$

$$*W_5 = W_5 - a (h_1 \cdot \Delta)$$

$$*W_4 = W_4 - a (i_2 \cdot \Delta W_6)$$

$$*W_3 = W_3 - a (i_1 \cdot \Delta W_6)$$

$$*W_2 = W_2 - a (i_2 \cdot \Delta W_5)$$

$$*W_1 = W_1 - a (i_1 \cdot \Delta W_5)$$

Güncelleme formüllerini matrislerde yerine yazılırsa;

$$* \begin{bmatrix} W_5 \\ W_6 \end{bmatrix} = \begin{bmatrix} W_5 \\ W_6 \end{bmatrix} - a \Delta \begin{bmatrix} h_1 \\ h_2 \end{bmatrix} = \begin{bmatrix} W_5 \\ W_6 \end{bmatrix} - \begin{bmatrix} a h_1 \Delta \\ a h_2 \Delta \end{bmatrix}$$

$$* \begin{bmatrix} W_1 & W_3 \\ W_2 & W_4 \end{bmatrix} = \begin{bmatrix} W_1 & W_3 \\ W_2 & W_4 \end{bmatrix} - a \Delta \begin{bmatrix} i_1 \\ i_2 \end{bmatrix} \cdot \begin{bmatrix} W_5 & W_6 \end{bmatrix} = \begin{bmatrix} W_1 & W_3 \\ W_2 & W_4 \end{bmatrix} - \begin{bmatrix} a i_1 \Delta W_5 & a i_1 \Delta W_6 \\ a i_2 \Delta W_5 & a i_2 \Delta W_6 \end{bmatrix}$$

Türetilmiş formüller kullanılarak ağın yeni çıktısı bulunabilir. Burada  $\Delta$ (Delta) değeri ağın ilk çalıştırıldığındaki çıktı değerinden ( $\zeta_1$ ) 1 çıkartılarak bulunur. Buradaki  $a$  ise öğrenme katsayısıdır ve kullanıcı tarafından manuel olarak belirlenir. Bulunan  $\Delta$  ve  $a$  değerleri yukarıdaki denkleme yazılarak matris hesabı yeniden yapılır ve ağın yeni çıktısı bulunur. Yeni çıktı eğitimden geçtiği için  $\zeta_1$  çıktısına göre çok daha iyi bir tahmin çıktısıdır.

#### 4.10.2. ÇKA Ağının Çalışma Prosedürü

ÇKA ağlarının çalışma adımları aşağıdaki gibidir:

- *Örneklerin toplanması:* Ağın çözeceği olayla ilgili daha önce gerçekleşmiş örneklerin hazırlanması adımıdır. Toplanan örneklerin bir kısmı ağın eğitimi için, bir kısmı da ağın test edilmesi için kullanılır. Ağ eğitilirken test için ayrılmış örnekler ağa gösterilmez. Ağ eğitim setindeki örneklerden iyice öğrendikten sonra test setindeki örnekler gösterilir. Bu şekilde ağın daha önce görmediği örnekler karşısındaki başarısı test edilmiş olunur.
- *Ağın topolojik yapısının belirlenmesi:* Yapay sinir ağının öğrenilmesi istenen olaya ve geçmiş örneklere göre yapısının belirlendiği aşamasıdır. Girdi katmanı sayısı, ara katman sayısı, sinir hücresi sayısı ve çıktı elemanı sayısı burada belirlenir.
- *Parametrelerin belirlenmesi:* Ağın öğrenme katsayısı, proses elemanlarının toplama ve aktivasyon fonksiyonlarının seçimi, momentum katsayısı gibi parametreler bu aşamada belirlenir.

- *Ağın başlangıç değerlerinin atanması:* Yapay sinir hücrelerindeki örneklerin ağırlık değerlerinin belirlendiği aşamadır. Başlangıçta ağırlık değerleri rastgele belirlenir, ağ öğrendikçe daha uygun değerleri kendisi belirler.
- *Öğrenme setinden örneklerin seçilmesi ve ağa gösterilmesi:* Ağın öğrenmeye başlaması için veri setindeki örneklerin(girdi ve çıktı değerleri) belirli bir orana göre ağa gösterildiği aşamadır.
- *İleri hesaplamaların yapılması:* Ağın öğrenmeye başlamasıyla birlikte ağa sunulan girdiler, ağırlık değerleriyle çarpılarak ve aktivasyon fonksiyonundan geçerek ağın çıktıları belirlenir.
- *Performans ölçülmesi:* Ağın bulduğu değerler ile gerçekleşen değerlerin karşılaştırıldığı aşamadır. Ağın üretmiş olduğu hata burada görülür.
- *Ağırlıkların belirlenmesi:* Ağın hatasını azaltarak daha iyi çıktı değerler alabilmek için geri yayılım kullanılarak ağırlıkların değiştirildiği aşamadır.

Yukarıdaki işlemler hata değerleri kabul edilebilir bir düzeye ulaşıncaya kadar devam eder. Hata değerleri istenilen düzeye geldiğinde ağın öğrenmesi tamamlanmış olur.

#### **4.10.3. Ağın Öğrenme Yerine Ezberleme Yapması**

Eğitilen çok katmanlı algılayıcı ağ eğitimi setindeki örneklere başarılı cevaplar üretmesine rağmen test setindeki örnekleri tahmin etmede başarılı olamamaktadır. Bu durumlarda ağın öğrenmeyerek veri setini ezberlediği anlaşılmaktadır. Ağın ezber yapmasından kurtulmak için ağ eğitimi sırasında gizli hücre sayısı, gizli katman sayısı ve öğrenme katsayısı gibi kritik parametreler alınan sonuçlara göre değiştirilmelidir, aksi takdirde ağ hep aynı mimaride tekrar tekrar çalıştırılırsa ezberleme yapması muhtemeldir.

Ezberlemeye neden olan bir başka durum ise yapay sinir ağları eğitilirken, eğitimin en uygun noktada durdurulması gerekmektedir. Eğer eğitim belirli bir noktadan sonra durdurulmayıp ağ eğitime devam edilirse ağın öğrenmekten ziyade eğitim verilerini ezberleyecektir. Bu yüzden durdurma kriteri ağın ezberleme yapıp yapmaması konusunda önem gösterilmesi gereken çok önemli bir parametredir. Veri setini ezberleyen bir ağ yerine düşük performanslı da olsa, azar azar öğrenen ve kabul edilebilir bir hata ile çalışan ağ daha iyidir.

## 5. TALEP TAHMİNİ UYGULAMASI

### 5.1. Firma ve Ürün Bilgisi

Talep tahmini uygulaması, iş makineleri sektöründe faaliyet gösteren Assan İş Makinaları(ASP Machinery) şirketinde yapılmıştır. ASSAN, iş makinelerinin önde gelen üreticileri olan Caterpillar, Komatsu, Kawasaki, Hitachi gibi dünya devi iş makinesi markalarına yedek parça imalatı yapmaktadır. Kepçe, Dozer gibi birçok iş makinesinin küçüğünden büyüğüne neredeyse tüm parçalarını üretmektedir. İş makineleri parçalarının satışını etkileyen faktörlerin belirlenmesinde yöneticilerin ve satış biriminin görüşlerine başvurulmuştur.

Talep tahmini yapılacak ürün gurubu olarak Manifold ürün gurubu seçilmiştir. Manifold ürün gurubu işletmenin en fazla ürettiği ürün gurubu olmakla birlikte, üretimi ve tezgâhları en çok meşgul eden ürün gurubudur. Manifold, iş makinelerinin hava girişi ve egzoz sistemi parçalarındandır. Tahmin yapılmak için seçilen manifold ürün gurubunda toplam 75 adet ürün bulunmaktadır.

İlerleyen bölümlerde iş makinelerinin önemli bir parçası olan manifold ürün gurubu için aylık talep tahmini probleminin çözüm aşamaları verilmiştir. Tahmin problemi yapay sinir ağları ile çözülmüştür. Ayrıca çoklu regresyon analizi ile de çözüm yapılmış, yöntemlerin tahmin başarısı test edilmiş ve karşılaştırılmıştır.

### 5.2. Talep Tahmininin Amacı

Assan, ürettiği ürünler için tedarikçilerine hammadde satın alma siparişlerini oluştururken, ürünlerin geçmiş senelerdeki satış adetlerini göz önünde bulundurarak hareket etmektedir. Yapılan tahminlerde geleneksel yöntemlerin kullanılması ve ürünün satışını etkileyecek önemli faktörlerin göz önünde bulundurulmaması, verilen bazı satın alma siparişlerinin gereğinden çok ya da gereğinden az olmasına neden olmaktadır. Bu da taşıma maliyetlerinden depolama maliyetlerine, makine hazırlık maliyetlerinden işçilik maliyetlerine çeşitli maliyetlere neden olmaktadır.

Assan, yedek parça üreten bir işletme olduğu için ürün çeşitliliği oldukça fazla olan bir işletmedir. Parça çeşitliliğinin fazla olması iyi bir üretim planlaması yapmayı da oldukça zorlaştırmaktadır. Bu nedenle işletmenin, ürünlere olan taleplerin zamanlarını ve miktarlarını iyi bilmesi, hangi malzemeden hangi zamanlarda stok tutması gerektiğini ortaya çıkaracak bu da iyi bir üretim planlaması yapılması için somut bir fikir olacaktır. Talebi etkileyen faktörlerin ortaya konulduğu profesyonel bir talep tahmin çalışması, geleceği önceden görmek ve tezgâh sayısı, işgücü miktarı, tedarikçi çeşitliliği, yeni parça ve pazarlara yönelme gibi çeşitli eylem planlarını almak açısından son derece önemli olacaktır.

### **5.3. Talep Tahmin Probleminin Tanımlanması ve Veri Setinin Hazırlanması**

Bu çalışmada iş makineleri sektöründe faaliyet gösteren bir işletmede, iş makinelerinin önemli parçalarından olan Manifold ürün gurubunun satışını etkileyecek faktörlerin belirlenmesi ve bu ürün gurubuna ait aylık satışların tahmin edilmesi amaçlanmaktadır. Yapılan tahminler üretim planlama ve stok yönetimi için girdi olarak kullanılacaktır.

Assan İş Makineleri yöneticileri ve satış birimiyle yapılan görüşmeler sonucunda manifold ürün gurubunun talebini etkileyen değişkenler aşağıdaki gibi belirlenmiştir.

- Dünyada satılan iş makinesi sayısı
- Dolar kuru
- Aylık etki oranı

Uygulamanın bağımlı değişkeni ise manifold ürün gurubunun aylık satış miktarlarıdır. Assan, Canias ERP yazılım sistemini aktif olarak tüm üretim ve yönetim süreçlerinde kullanmaktadır. Uygulamada kullanılan veriler ERP veri tabanından elde edilmiştir. Belirlenen ürün gurubu ile ilgili satış verileri aylık olarak sorgulanmış ve özet tablolar oluşturulmuştur. Tahmin çalışması için 2010-2018 yılları arasındaki 108 aylık veriler toplanmıştır. Değişkenlerin seçim nedenleri ve özet veri setleri aşağıdaki gibidir.

***Aylık Satış Miktarı Verileri:*** Manifold ürün gurubu için 75 adet ürün seçilmiş ve her biri için aylık satış adetleri ERP sisteminden elde edilmiştir. Aylık satış miktarı verileri Çizelge 5.1' de gösterilmiştir.

**Çizelge 5.1.** Aylık satış miktarı verileri

MANIFOLD Aylık Satış	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2010	756	545	720	710	805	650	834	712	910	696	562	603
2011	805	650	1120	847	1428	935	1421	1555	1192	903	658	913
2012	862	749	1240	915	1126	841	1413	1012	850	704	852	876
2013	732	890	1466	751	1202	891	1357	1036	612	995	829	884
2014	819	752	805	945	1339	884	926	848	1117	791	1114	983
2015	606	953	462	427	851	670	694	590	273	699	807	739
2016	606	484	414	761	849	643	1104	874	598	755	926	462
2017	910	400	968	971	1039	1714	802	1248	667	669	868	965
2018	836	561	1456	833	1277	597	1436	406	1186	649	670	966

**Dünyada Satılan İş Makinesi Sayısı:** Dünyada satılan iş makinesi sayısının talebi etkileyeceği düşünülerek 2010-2018 arasında dünya üzerinde yıllık olarak satılan iş makinesi verilerine ulaşılmıştır. Ulaşılan veriler işletmenin ürettiği markalarla uyumlu olarak Caterpillar, Komatsu, Kawasaki, Hitachi gibi markaların iş makinelerine ait satış verileridir. Veriler Avrupa, Kuzey Amerika, Japonya, Çin ve Hindistan gibi büyük pazarlara ait olduğundan tüm dünyadaki satışı temsil etmektedir. Ulaşılan veriler yıllık bazda satılan makine sayısını gösterdiğinden verileri aylık baza çevirmek için aylık satışların yıllık toplam satışın yüzde olarak ne kadarını temsil ettiğine bakılmış, dünyada satılan yıllık iş makinesi sayılarının bu yüzdeye göre aylık satışlara çevrilebileceği düşünülmüştür. Yapılan işlemler eşitlik 5.1 ve 5.2’de gösterilmiştir.

$$(AS*100) / YTS = TY \quad (5.1)$$

$$YSİS * ( TY / 100 ) = ASMS \quad (5.2)$$

Eşitliklerde;

AS: Aylık satış miktarı

YTS: Yıllık toplam talep adedi

TY: Temsili yüzde

YSİS: Dünya üzerinde yıllık satılan toplam iş makinesi sayısı

ASMS: Dünya üzerinde aylık satılan iş makinesi sayısını temsil etmektedir.

**Çizelge 5.2.** Dünya yıllık iş makinesi satış adetleri [49,50]

Dünya Yıllık İş Makinesi Satışı	2010	2011	2012	2013	2014	2015	2016	2017	2018
<b>Avrupa</b>	100993	123706	118899	1111856	124780	125710	130500	132670	131250
<b>Kuzey Amerika</b>	90600	124215	146830	158096	171310	177940	186030	175690	160610
<b>Japonya</b>	37060	47085	64860	90830	84230	80000	73830	71620	71650
<b>Çin</b>	401480	435070	290205	273720	209760	131350	137820	147430	156990
<b>Hindistan</b>	42811	54053	50795	42708	36810	38550	46410	54180	59280
<b>Toplam Miktar</b>	672944	784129	671589	1677210	626890	553550	574590	581590	579780

Manifold gurubu ürünlerin aylık satış miktarlarına göre eşitlik 5.1 ve eşitlik 5.2 kullanılarak aylık baza çevrilen iş makinesi satış adetleri Çizelge 5.3' de gösterilmiştir.

**Çizelge 5.3.** Dünya aylık iş makinesi satış adetleri

Dünya Aylık Satılan Makine	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
<b>2010</b>	59831	43132	56982	56191	63709	51442	66004	56349	72019	55083	44478	47723
<b>2011</b>	50795	41014	70671	53445	90105	58997	89663	98119	75214	56978	41519	57609
<b>2012</b>	50604	43970	72795	53715	66102	49371	82951	59410	49900	41329	50017	51426
<b>2013</b>	42569	51758	85255	43674	69902	51816	78916	60248	35591	57864	48210	51409
<b>2014</b>	45343	41634	44568	52319	74133	48942	51267	46949	61842	43793	61676	54423
<b>2015</b>	43167	67885	32910	30416	60619	47726	49436	42027	19447	49792	57485	52641
<b>2016</b>	41081	32810	28065	51588	57554	43589	74840	59249	40539	51182	62774	31319
<b>2017</b>	47166	20732	50172	50327	53852	88837	41568	64684	34571	34675	44989	50016
<b>2018</b>	44578	29914	77638	44418	68093	31834	76572	21649	63241	34607	35726	51510

**Aylık Dolar Kuru:** Dolar kuru bir Amerikan dolarının Türk Lirası karşısındaki değerini belirtmektedir. İşletme çoğunluk olarak yurtdışına çalışsa da satışlarının azımsanmayacak bir kısmını da yurt içine yapmaktadır. Yurt içinden ürün talep eden firmalar için dolar kuru şüphesiz önemli bir faktördür. Ayrıca hem yurt içi hem yurt



dışı satışlarda dolar kurunun önemli olduğu bir başka neden ise hammadde alımlarıdır. Döküm ve çelik gibi hammaddeler veya hammaddelerin içerisindeki metal alaşımları yurtdışından dolar hesabıyla alındığı için yüksek fiyatlardan alınmaktadır. Doların yüksek olduğu zamanlarda hammadde fiyatları yüksekken düşük olduğu zamanlarda daha uydun fiyatlara hammadde temini sağlanabilmektedir. Hammadde fiyatları düşük olsa müşterilere daha uygun ürün fiyatları sunulabilir. Müşteriler için fiyat önemli bir kriterdir. Bu yüzden dolar kuru satışı etkileyen önemli bir değişkendir.

Dolar kuru hesaplanırken 2010-2018 yılları arasında aylık dolar kuru alış ve satış verileri toplanmış ve aritmetik ortalaması alınmıştır. Türk Lirasının geçmişteki değeriyle şimdiki değeri bir olmayacağından yapay sinir ağlarında dolar kuru verilerini aynen kullanmanın yanlış olacağı düşünülmüştür. Bu nedenle tüm yıllardaki dolar kur değerleri, Türkiye İstatistik Kurumu'nun (TÜİK) tüketici fiyat endeksine (TÜFE) göre hesapladığı enflasyon hesaplayıcısı [51] kullanılarak 2018 yılı aylarındaki Türk Lirası değerlerine çevrilmiştir. Böylelikle tüm yıllar için alım gücü ortak bir şekilde ifade edilmiştir. Aylık dolar kuru verileri Çizelge 5.4' de gösterilmiştir.

**Çizelge 5.4.** Aylık dolar kuru verileri [52]

Dolar Kuru (Alış+Satış)/2	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2010	1.47	1.51	1.53	1.49	1.54	1.56	1.54	1.51	1.49	1.42	1.43	1.52
2011	1.56	1.59	1.58	1.52	1.57	1.60	1.65	1.75	1.79	1.83	1.80	1.86
2012	1.84	1.76	1.78	1.78	1.80	1.82	1.81	1.79	1.80	1.80	1.79	1.78
2013	1.77	1.77	1.81	1.80	1.82	1.90	1.93	1.96	2.02	1.99	2.02	2.06
2014	2.22	2.22	2.22	2.13	2.09	2.12	2.12	2.16	2.21	2.26	2.23	2.29
2015	2.33	2.46	2.59	2.65	2.64	2.70	2.69	2.85	3.01	2.93	2.88	2.92
2016	3.00	2.94	2.89	2.84	2.93	2.92	2.95	2.96	2.96	3.07	3.28	3.49
2017	3.74	3.67	3.67	3.65	3.57	3.52	3.56	3.51	3.47	3.67	3.88	3.85
2018	3.77	3.78	3.88	4.05	4.41	4.63	4.75	5.80	6.34	5.85	5.38	5.30

Enflasyon hesaplayıcısı kullanılarak 2018 yılı Türk Lirası değerlerine çevrilen dolar kuru verileri Çizelge 5.5' de gösterilmiştir.

**Çizelge 5.5.** Enflasyona göre düzenlenmiş aylık dolar kuru verileri [51]

Enf. Hesaplı Dolar Kuru	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2010	2.8	2.85	2.9	2.86	3.01	3.16	3.14	3.13	3.26	3.13	3.11	3.29
2011	2.82	2.88	2.88	2.79	2.86	3.04	3.16	3.41	3.67	3.74	3.57	3.65
2012	3.02	2.88	2.94	2.95	3.03	3.18	3.18	3.21	3.39	3.41	3.33	3.3
2013	2.70	2.72	2.78	2.81	2.88	3.06	3.12	3.24	3.53	3.50	3.51	3.55
2014	3.15	3.15	3.15	3.04	3.02	3.13	3.14	3.26	3.54	3.65	3.55	3.64
2015	3.08	3.25	3.41	3.51	3.53	3.72	3.72	4.02	4.46	4.40	4.23	4.27
2016	3.61	3.57	3.55	3.52	3.67	3.74	3.75	3.87	4.10	4.30	4.51	4.70
2017	4.13	4.05	4.05	4.05	4.01	4.06	4.13	4.14	4.31	4.59	4.72	4.63
2018	3.77	3.78	3.88	4.05	4.41	4.63	4.75	5.80	6.34	5.85	5.38	5.30

**Aylık Etki Oranı:** Satış verilerindeki dalgalanmalara bakıldığında müşteri taleplerinin mevsimsel etkilerden ziyade daha kısa bir zaman aralığında aylık olarak değişiklik gösterdiği gözlenmiştir. Aylık satışların, yıllık ortalama satışlardan yüzde olarak ne derece altında ya da üstünde olduğu hesaplanarak satışlara olan aylık etki değerleri değişken olarak belirlenmiştir. Yıllık ortalama satışların altında kalan aylık satış değerleri yüzde olarak negatif aylık etki değerleri oluşturacağından 100 ekleyerek sınır ağlarının anlayabileceği şekle dönüştürülmüştür.

$$OAA = (AT*100) / OT - 100 \quad (5.3)$$

$$AEO = OAA + 100 \quad (5.4)$$

Formüllerdeki açıklamalar aşağıdaki gibidir:

OAA: Ortalamaya göre yüzdece azalış ya da artış değeri

AT: Aylık talep

OT: Ortalama talep

AEO: Aylık etki oranı

Manifold ürün gurubu için hesaplanan aylık satış etki oranları Çizelge 5.6' da gösterilmiştir.

**Çizelge 5.6.** Aylık etki oranı değerleri

AEO	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2010	107	77	102	100	114	92	118	100	128	98	79	85
2011	78	63	108	82	138	90	137	150	115	87	64	88
2012	90	79	130	96	118	88	148	106	89	74	89	92
2013	75	92	151	77	124	92	140	107	63	103	85	91
2014	87	80	85	100	142	94	98	90	118	84	118	104
2015	94	147	71	66	131	103	107	91	42	108	125	114
2016	86	69	59	108	120	91	156	124	85	107	131	65
2017	97	43	104	104	111	183	86	133	71	72	93	103
2018	92	62	161	92	141	66	158	45	131	72	74	107

#### 5.4. Tahmin Yönteminin Seçilmesi


Geleneksel zaman serisi yöntemleriyle yapılan tahminler bilinen ve en çok kullanılan tahmin yöntemleridir fakat zaman serisi yöntemlerinin talebe neden olan değişkenleri dikkate almayarak doğrudan satış verileri üzerinden hesaplar yapması yanıltıcı sonuçlar verebilir. Ayrıca zaman serileri analizleri düzgün olmayan ve dalgalanmaların çok olduğu veri setlerinde yüksek hata oranları gösterebilir. Yine tahmin modellerinde sık kullanılan ve ekonometrik modellerden olan Box-Jenkins modelleri ise kesikli ve stokastik süreçlere dayanmaktadır. Ancak zaman serilerinin ortaya çıktığı gerçek hayat problemleri genellikle durağan değildir.

Talebe neden olan değişkenleri iyi analiz edecek yöntemlerin kullanılması tahminlerde daha doğru sonuçlar aldırabilir. Yapay sinir ağları 1980'li yıllardan itibaren zaman serileri analizlerinde kullanılmaktadır. Doğrusal olmayan zaman serilerini modellemedeki başarısı birçok uygulamada gösterilmiştir. Ayrıca YSA bağımlı ve bağımsız değişkenler arasında herhangi bir ön bilgiye sahip olmadan gerekli modellemeyi sağlayan önemli bir tahmin yöntemidir. Bu nedenle çalışmada tahmin aracı olarak diğer tahmin yöntemlerine göre daha avantajlı ve başarılı sonuçlar üretebilen yapay sinir ağları metodu seçilmiştir. Ayrıca talebi etkileyen değişkenler arasındaki ilişkiyi açıklayan bir yöntem olan çoklu regresyon analizi ile de tahmin yapılmış ve sonuçlar karşılaştırılmıştır.

## 5.5. Yapay Sinir Ağı Mimarisinin Oluşturulması Ve Eğitimi

Uygulama, Matlab (R2016a sürümü) yazılımı ile gerçekleştirilmiştir. Uygulamada talep tahmininde en çok kullanılan yöntem olan geri yayılım algoritması kullanılmıştır. Tahmin yapılırken ağırlıkların belirlenmesinde aktivasyon fonksiyonu olarak “tansig” “logsig” , “purelin” gibi türevi alınabilir fonksiyonlar denenmiştir. Denemeler sonucunda “logsig” fonksiyonu ile daha başarılı sonuçlar alındığı için “logsig” fonksiyonu seçilmiştir. Matlab’ da eğitim fonksiyonu olarak da birçok geri yayılım fonksiyonu bulunmaktadır. Bunlardan bazıları “trainbfg” , “trainbr” , “traincgf” , “traingdm” , “traingdx” , “trainlm” , “trainoss” ve “trainrp” ’dir. Bu fonksiyonlar denenmiş, denemeler sonucunda ağın en iyi öğrendiği fonksiyon, **trainrp** (Resilient backpropagation) olarak gözlemlenmiş ve bu fonksiyon seçilmiştir. Resilient backpropagation (Rprop) kısmi türevlerin büyüklüklerini ve zararlı etkilerini ortadan kaldıran esnek bir geri yayılım algoritmasıdır.

2010-2018 yılları arasındaki 108 adet veriden, 2010-2017 yılları arasındaki 96 adet veri ağın eğitimi için kullanılırken 2018 yılındaki 12 adet veri test için seçilmiştir. Yapay sinir ağı model mimarisi 1 giriş katmanı, 2 gizli katman ve 1 çıkış katmanından oluşmaktadır. Giriş katmanında 3, ilk gizli katmanda 6 nöron, ikinci gizli katmanda 3 nöron ve çıkış katmanında 1 nöron bulunmaktadır (3x6x3x1) . Ağ mimarisi Şekil 5.1’de gösterilmiştir.



Şekil 5.1. Ağ mimarisi

YSA mimarisi oluşturulurken gizli katmanlardaki hücre sayıları belirlenmesinde “Geometrik piramit kuralı” adı verilen kuraldan faydalanılmıştır. Piramit kuralına göre gizli katmanlardaki hücre sayılarının çıkış katmanına doğru azalarak gitmesi

gerekmektedir. Ayrıca gizli katmanlardaki hücre sayılarının, girdi hücre sayısının 2 katını geçmemesi gerekmektedir. Bu kural çerçevesinde yapılan denemeler sonucunda birinci katmandaki hücre sayısı 6, ikinci katmandaki hücre sayısı 3 olduğunda en iyi mimari ortaya çıkmıştır.

### **5.5.1. Öğrenme Katsayısının Belirlenmesi**

Ağın öğrenme katsayısının belirlenmesi sinir ağının performansı için çok önemli bir parametredir. Öğrenme katsayısı toplam hatayı en aza indirmek için ağırlıkların değişim miktarını belirlemede kullanılmaktadır. Öğrenme katsayısının düşük olması ağın öğrenme süresinin artmasına neden olurken, büyük öğrenme katsayıları ağın yerel çözümler arasında dolaşmasına neden olur.

Öğrenme katsayısını belirlemek için belirli bir yöntem yoktur, eğitim sırasında kullanıcı tarafından belirlenmektedir. Bu çalışmada öğrenme katsayısı belirlenirken 0.5-0.9 arasında değerler için denemeler yapılmıştır. En iyi hata oranının alındığı ve ağın en iyi öğrendiği öğrenme katsayısı 0.7 olarak belirlenmiştir.

### **5.5.2. Çevrim Sayısının Belirlenmesi**

Belirli bir iterasyondan sonra ağ bulduğu değerleri tekrar etmeye başlar yani ağın öğrenmesi durur. Bu noktadan sonra ağın daha fazla öğrenemeyeceği ve daha iyi bir sonuç bulamayacağı anlaşılmaktadır. Uygulamada mevcut veri sayısı göz önünde bulundurularak çevrim sayısı 10000 olarak belirlenmiş ve yeterli görülmüştür. En iyi YSA mimarisinin oluşturulması sırasındaki deneme yanılma sonuçları Çizelge 5.7’de gösterilmiştir.

**Çizelge 5.7.** En iyi YSA mimarisi için deneme yanılma sonuçları

Gizli Katman Sayısı	Aktivasyon Fonksiyonu	Her Katmandaki Nöron Sayısı	Eğitim Fonksiyonu	Öğrenme Katsayısı	MAPE	R <sup>2</sup>
1	logsig	1	trainlm	0.5	0.07794	0.95520
	logsig	2	trainlm	0.6	0.06651	0.94810
	logsig	3	trainoss	0.7	0.10056	0.93996
	purelin	6	trainbfg	0.8	0.09366	0.92692
	tansig	8	trainlm	0.9	0.17505	0.50514
	tansig	10	trainrp	0.6	0.07527	0.94754
	logsig	10	traincgf	0.7	0.09545	0.84036
	logsig	12	trainlm	0.8	0.09475	0.91707
	logsig	15	trainbr	0.6	0.09521	0.89173
	logsig	15	trainlm	0.7	0.11352	0.57003
2	tansig	1-1	trainlm	0.5	0.06448	0.96218
	purelin	3-3	trainlm	0.6	0.12641	0.78486
	purelin	5-5	trainbfg	0.7	0.13080	0.79473
	logsig	5-4	trainbfg	0.8	0.12673	0.85568
	<b>logsig</b>	<b>6-3</b>	<b>trainrp</b>	<b>0.7</b>	<b>0.04990</b>	<b>0.97890</b>
	logsig	10-5	trainoss	0.9	0.12919	0.85534
	tansig	10-8	trainrp	0.7	0.08734	0.95748
	logsig	10-10	trainrp	0.8	0.07954	0.91453
	logsig	15-10	trainrp	0.6	0.06969	0.9535
	logsig	15-15	trainlm	0.7	0.11701	0.86562

## 5.6. Matlab’da Yazılan Kodlar

Matlab’da yapay sinir ağını oluşturmak ve talep tahmin uygulamasını gerçekleştirmek için aşağıdaki adımlar izlenmiştir.

### 5.6.1. Veri Setinin Matlab’a Okutulması

İlk olarak talep tahmini yapmak için toplanan ve Microsoft Excel programına kayıtlı olan veriler Matlab’a okutulmuştur.

Daha sonra bağımlı ve bağımsız değişkenlerin her biri için toplanan 108 adet verinin 96 adeti ağı eğitimi için, 12 adeti ise test için kullanılmıştır. Yazılan kodlar Şekil 5.2’de gösterilmiştir.

```
Command Window
>> veri=xlsread('sales.xlsx');
>> input=veri(:,1:3);
>> target=veri(:,end);
>> noofdata=size(input,1);
>> training_rate=0.89;
>> ntd=round(noofdata*training_rate);
>> xt=input(1:ntd,:);
>> xv=input(ntd+1:end,:);
>> yt=target(1:ntd);
>> yv=target(ntd+1:end);
fx >> |
```

**Şekil 5.2.** Verilerin okutulması ve ayrılması için kodlar

YSA'nın öğrenbilmesi için aşağıdaki işlemler gerçekleşecektir:

1. Bağımsız değişken verileri (girdiler) eğitim ve test verileri olarak ayrılır.
2. Bağımlı değişken verileri (çıktılar) eğitim ve test verileri olarak ayrılır.
3. Eğitim girdileri ve çıktıları kullanılarak ağ eğitilir.
4. Test girdileri ve çıktıları ağa verilerek eğitilmiş ağdan çıkan çıktılarla gerçek çıktılar karşılaştırılır.

### 5.6.2. Verilerin Normalize Edilmesi

Girdi ve çıktı değerleri ağa sunulmadan önce [0 1] aralığında yada [-1 1] aralığında normalize edilmelidir. Normalizasyon işlemi veriler arasındaki büyüklük farklarının azaltarak verileri bir aralıkta sınırlandırır. Çalışmadaki veriler [-1 1] aralığında normalize edilmiştir. Ayrıca Matlab'da bütün işlemler matris formunda yapılmaktadır. Excel'de bulunan veriler satırlarda olduğu için verilerin transpozu alınarak verilerin sütunlarda olması yani matris formuna dönüşmesi sağlanmıştır. Yazılan kodlar Şekil 5.3'te gösterilmiştir.

```
Editor - C:\Program Files\MATLAB\R2016a\bin\neuralnetworkmnf.m
neuralnetworkmnf.m x +
10 - xt=xt';
11 - xv=xv';
12 - yt=yt';
13 - yv=yv';
14 - xtn=mapminmax(xt);
15 - xvn=mapminmax(xv);
16 - [ytn, ps]=mapminmax(yt);
```

Şekil 5.3. Verilerin matris forma dönüşmesi ve normalizasyonu

### 5.6.3. Sinir Ağının Oluşturulması ve Parametrelerinin Belirlenmesi

Yapay sinir ağını oluşturmak için öncelikle ağ objesi oluşturulmalıdır. Ağ objesi ağ ile ilgili hücre sayısı, eğitim ve aktivasyon fonksiyonu gibi bilgileri barındıran bir yapıdır. İleri beslemeli geri yayımlı bir ağ oluşturulmuştur. Daha sonra öğrenme katsayısı ve gidilecek iterasyon sayısı gibi parametreler belirlenmiştir. Yazılan kodlar Şekil 5.4'te gösterilmiştir.

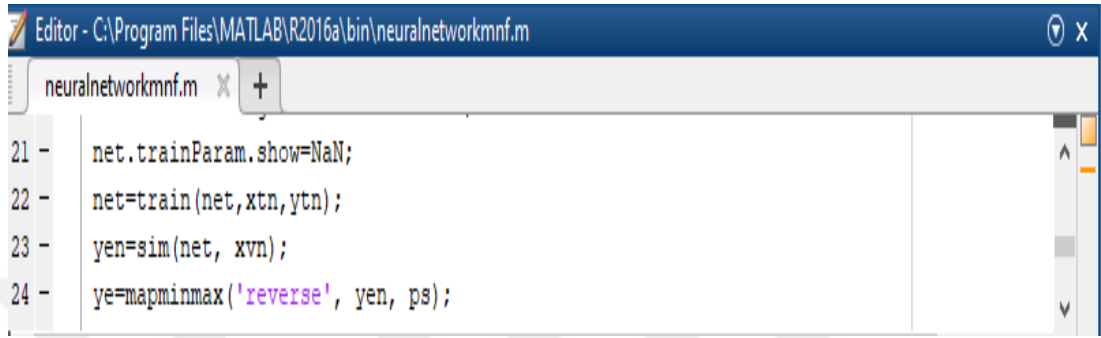
```
Editor - C:\Program Files\MATLAB\R2016a\bin\neuralnetworkmnf.m
neuralnetworkmnf.m x +
17 - net=newff(xtn, ytn, [n1,n2], {'logsig'}, 'trainrp');
18 - net.trainParam.lr=lr;
19 - net.trainParam.epochs=10000;
20 - net.trainParam.goal=1e-10;
21 - net.trainParam.show=NaN;
```

Şekil 5.4. Sinir ağının oluşturulması



#### 5.6.4. Sinir Ağının Eğitilmesi

Bu aşama eğitim girdi verileri ve eğitim çıktı verileri kullanılarak ağı eğitildiği aşamadır. Ağ çalıştığında alınacak tahmini değerlerin yorumlanabilmesi için daha önceden normalize edilen test girdi değerleri bu aşamada denormalize edilir. Yazılan kodlar Şekil 5.5'te gösterilmiştir.



```
Editor - C:\Program Files\MATLAB\R2016a\bin\neuralnetworkmnf.m
neuralnetworkmnf.m x +
21 - net.trainParam.show=NaN;
22 - net=train(net,xtn,ytn);
23 - yen=sim(net, xvn);
24 - ye=mapminmax('reverse', yen, ps);
```

Şekil 5.5. Sinir ağının eğitilmesi

Bu aşamada ara katmanlardaki hücre sayıları ve öğrenme katsayıları kullanıcı tarafından yapılan denemelerle belirlenir. Ağ çalıştıktan ve eğitildikten sonra son aşama ağı performansının test edilme aşamasıdır.

#### 5.6.5. Sinir Ağının Performansının Test Edilmesi

Bu aşamada gerçekleşen taleplerle sinir ağının bulduğu tahmini talepler karşılaştırılarak ağı performansı ölçülür. Ağı bulduğu değerleri Excel'de karşılaştırma yapmak için ağı bulduğu çıktıların ve gerçekleşen çıktıların transpozu alınır. Oluşan hatayı tespit etmek için performans ölçütü olarak Ortalama Mutlak Hata Yüzdesi (MAPE) ölçütü kullanılmıştır. Yazılan kodlar Şekil 5.6'da gösterilmiştir.

```

Editor - C:\Program Files\MATLAB\R2016a\bin\neuralnetworkmnf.m
neuralnetworkmnf.m x +
1 function [ net ye yv MAPE R2 ] = neuralnetworkmnf( input, target, training_rate, n1, n2, lrate )
25 - ye=ye';%NN ciktisi
26 - yv=yv';%Gerçeklesen cikti
27 - MAPE= mean( (abs(ye-yv) ) ./yv);
28 - Sstotal= sum( (yv-mean(yv) ) .^2);
29 - Sserror= sum( (ye-yv) .^2);
30 - R2=1-Sserror/Sstotal;
31
32 - end

```

Şekil 5.6. Ağın performansının ölçülmesi

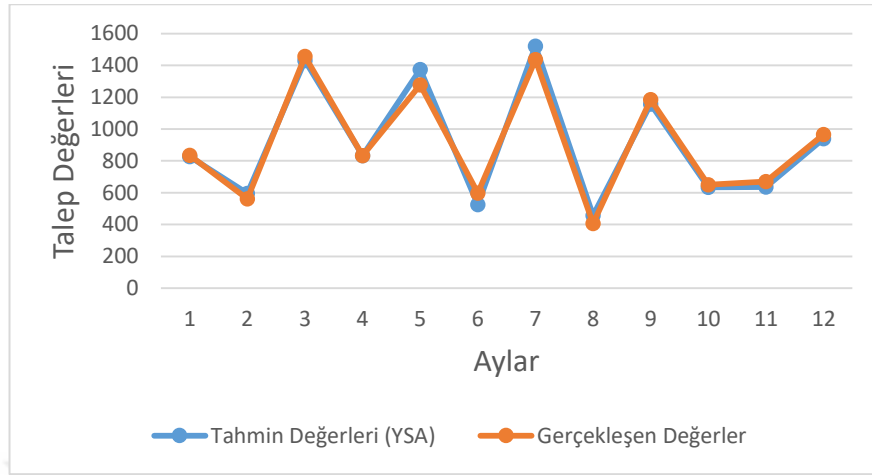
### 5.7. YSA Tahmin Sonuçları

Yapay sinir ağlarıyla yapılan talep tahmini %95 doğrulukla gerçekleşmiştir. Tahminlerde MAPE değerinin 0'a yakın,  $R^2$  değerinin ise 1'e yakın olması istenir. Tahmin sonucunda MAPE değeri 0'a çok yakın, 0.0499 olarak bulunmuştur yani %4.9' luk bir hata payı meydana gelmiştir. Bağımlı değişkendeki bağımsız değişkenden tahmin edilen varyansın oranı olan  $R^2$  değeri ise 1'e çok yakın, 0.9789 olarak bulunmuştur. Sonuçlar Çizelge 5.8'de gösterilmiştir.

Çizelge 5.8. YSA tahmin sonuçları


Ağın Bulduğu Tahmin Değerleri (ye)	Gerçekleşen Değerler (yv)	Aylar	Tahmin Doğruluğu (%)	Sapma (Adet)
827	836	Ocak	98.97%	9
596	561	Şubat	93.74%	35
1431	1456	Mart	98.29%	25
832	833	Nisan	99.92%	1
1375	1277	Mayıs	92.35%	98
525	597	Haziran	87.87%	72
1521	1436	Temmuz	94.07%	85
458	406	Ağustos	87.30%	52
1158	1186	Eylül	97.62%	28
634	649	Ekim	97.73%	15
635	670	Kasım	94.79%	35
940	966	Aralık	97.36%	26
		<b>Ortalama</b>	<b>95%</b>	<b>40</b>

Gerçekleşen talepler ile YSA'nın bulduğu tahmini talepler Şekil 5.7'de gösterilmiştir.



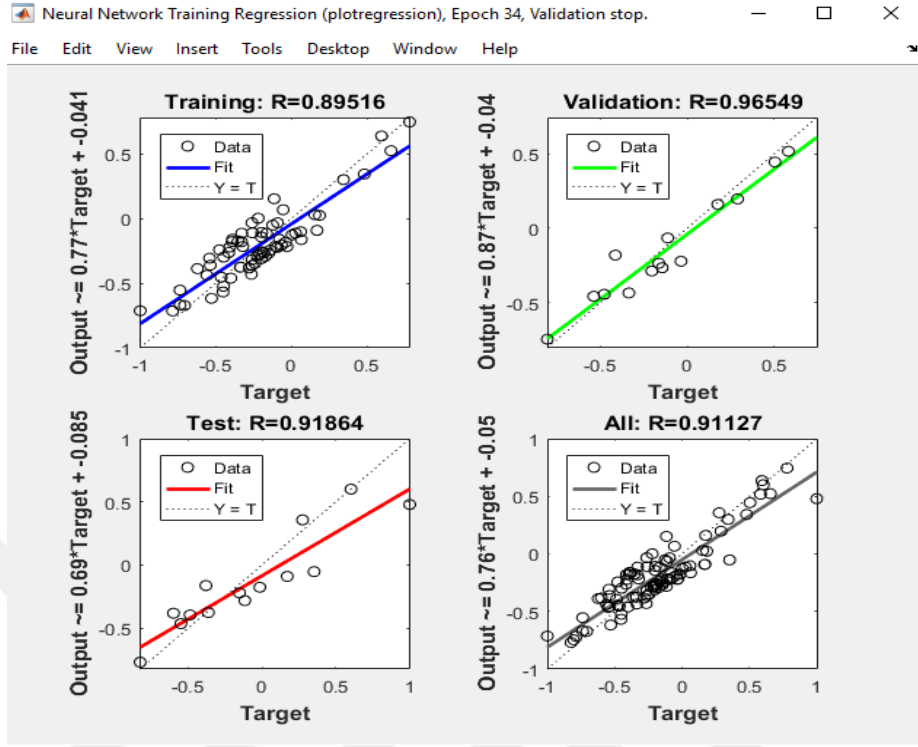
Şekil 5.7. YSA tahmin sonuçlarının gerçekleşen taleplerle karşılaştırılması

Ağın eğitimi sonucunda her iterasyondaki eğitim doğrulama ve test kümelerinin ne şekilde değiştiğini gösteren performans grafiği Şekil 5.8'de gösterilmiştir. Grafikten görüldüğü üzere 34 iterasyonda optimum sonuca ulaşılmıştır.



Şekil 5.8. Performans grafiği

Regresyon grafiđi Őekil 5.9’da gsterilmiŐtir. ğrenme iŐlemi byk bir baŐarıyla gerekleŐmiŐtir.



Őekil 5.9. Regresyon grafiđi

OluŐturulan YSA modeli, 3x96 giriŐ matrisi ve 1x12 ıkıŐ matrisi ile eđitildikten sonra, ađın eđitimi ile ilgili ađ ilerleme verileri izelge 5.9’ de gsterilmiŐtir. Ađ 0’a ok yakın olan 1.00e-05 hata deđeri ile alıŐmıŐtır.

izelge 5.9. Ađ ilerleme verileri

<i>İlerleme Verileri</i>	<i>Veri</i>
İterasyon	34
Zaman	5.2 sn
Performans	1.00e-05
Eđim	0.0127

## 5.8. Çok Değişkenli Regresyon Analizi İle Tahmin Uygulaması

Çok değişkenli regresyon analizi yapılırken tüm tahmin değişkenlerinin bir arada modele eklendiği enter metodu kullanılmıştır. Az sayıda değişken olduğu için enter metodu uygun görülmüştür

Çoklu regresyon analizi IBM SPSS Statistics 21 yazılımı kullanılarak yapılmıştır. Regresyon analizi sonucunda değişken katsayıları Çizelge 5.10'daki gibi bulunmuştur.

**Çizelge 5.10.** Çok değişkenli regresyon ağırlık katsayıları

Çoklu Regresyon Çözümü	$a_0$	$a_1$	$a_2$	$a_3$
Katsayılar	-241.571	0.017	56.533	0.048

Modelde X bağımsız değişkenleri (girdi verilerini) ve Y bağımlı değişkenleri (çıktı verilerini) temsil etmektedir. Çoklu regresyon denklemini aşağıdaki gibi oluşturulmuştur.

$$Y = a_0 + a_1X_1 + a_2X_2 + a_3X_3 \quad (5.5)$$

$a_0$  = sabit değer

$a_1$  = dünyada satılan iş makinesi sayısı bağımsız değişkeninin ağırlık katsayısı

$a_2$  = dolar kuru değişkeninin ağırlık katsayısı

$a_3$  = aylık etki oranı bağımsız değişkeninin ağırlık katsayısı

$X_1$  = dünyada satılan iş makinesi sayısı

$X_2$  = dolar kuru

$X_3$  = aylık etki oranı

Şekil 5.10'da bulunan katsayılar denklemde yerine konularak çoklu regresyon denklemini aşağıdaki gibi oluşturulmuştur:


$$Y = -241.571 + 0.017 X_1 + 56.533 X_2 + 0.048 X_3 \quad (5.6)$$

Bulunan denkleme 2017 yılı bağımsız değişken verileri yazılarak 2018 yılı için talep tahmini yapılmıştır. Tahmin sonuçları Çizelge 5.11’de gösterilmiştir.

**Çizelge 5.11.** Çok değişkenli regresyon analizi tahmin sonuçları

Çoklu Regresyon Tahmin Değerleri	Gerçekleşen Değerler	Aylar	Tahmin Doğruluğu (%)	Sapma (Adet)
798	836	Ocak	95.51%	37.56
342	561	Şubat	60.95%	219.09
845	1456	Mart	58.06%	610.70
848	833	Nisan	98.20%	14.96
906	1277	Mayıs	70.95%	371.01
1507	597	Haziran	-52.43%	910.03
703	1436	Temmuz	48.94%	733.29
1099	406	Ağustos	-70.58%	692.55
593	1186	Eylül	50.02%	592.75
611	649	Ekim	94.12%	38.15
795	670	Kasım	81.41%	124.54
875	966	Aralık	90.63%	90.54
		<b>Ortalama</b>	<b>52.15%</b>	<b>369.60</b>

Regresyon analizi sonucunda %52.15’lik bir tahmin başarısı elde edilmiştir. Gerçekleşen talepler ile YSA’nın bulduğu tahmini talepler Şekil 5.10’da gösterilmiştir.



**Şekil 5.10.** Çoklu regresyon tahmin değerleri ve gerçekleşen değerler

Regresyon analizi Model özeti Şekil 5.11’de gösterilmiştir.

**Model Summary<sup>b</sup>**

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,922 <sup>a</sup>	,849	,845	107,841216	,256

a. Predictors: (Constant), aylık\_etki, dolar\_kuru, sat\_makine\_sayisi

b. Dependent Variable: satis\_miktari

**Şekil 5.11.** Regresyon analizi model özeti

Adjusted R<sup>2</sup> değeri 0.845 olarak hesaplanmıştır. Yani bağımsız değişkenler (dünyada satılan iş makinesi sayısı, dolar kuru, aylık etki oranı), bağımlı değişkendeki (satis miktarı) değişimin %84.9’unu açıklayabilmektedir. Bu değer oldukça yüksek bir değerdir.

ANOVA testi de anlamlı çıkmıştır Sig(P) değeri 0.000’dır. Yani regresyon modeli bütün olarak anlamlıdır. SPSS’ te yapılan Anova testi ise Şekil 5.12’de gösterilmiştir.

**ANOVA<sup>a</sup>**

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	6824736,186	3	2274912,062	195,612	,000 <sup>b</sup>
	Residual	1209491,693	104	11629,728		
	Total	8034227,880	107			

a. Dependent Variable: satis\_miktari

b. Predictors: (Constant), aylık\_etki, dolar\_kuru, sat\_makine\_sayisi

**Şekil 5.12.** Regresyon analizi anova testi

## 6. SONUÇ VE DEĞERLENDİRME

Bu çalışma yapay zeka teknolojilerinden olan yapay sinir ağlarının tahmin yapmadaki başarısını göstermek amacıyla hazırlanmıştır. Verilerin doğrusal olmadığı ve talebi etkileyen birden fazla değişkenin olduğu tahmin problemlerinde YSA'nın nasıl etkin sonuçlar verdiği gösterilmiştir. İş makineleri sektöründe uygulanan bu çalışmada, seçilen bir ürün gurubu için son 9 yılın satış verilerinden yararlanılarak talep tahmini yapılmıştır.

İş makinelerinin hava girişi ve egzoz sistemi parçalarından olan manifold ürün gurubu için 2010-2018 yılları arasındaki aylık satış verileri adetsel olarak toplanmıştır. Yıllık satışları etkileyen faktörler yöneticilerle ve satış ekibiyle yapılan görüşmeler sonucunda belirlenmiştir.

Elde edilen veri setine göre yapay sinir ağlarının uygun mimarisini elde etmek için çeşitli kaynaklar taranmış ve edinilen bilgilere uygun olarak birçok denemeler yapılmıştır. Sonuçta en uygun ağ mimarisi bulunmuştur. 2010-2017 yılları arasındaki 96 aylık veri seti ağı eğitimi için kullanılırken, 2018 yılındaki 12 aylık veriler ağı test edilmesi için kullanılmıştır. YSA ile yapılan tahmin sonucunda %4.9'luk bir hatayla %95 oranında bir tahmin başarısı elde edilmiştir.

Ayrıca çok değişkenli regresyon analizi ile de talep tahmini yapılmış, oluşturulan model sonucunda % 52.15 oranında bir tahmin başarısı elde edilmiştir. Yapay sinir ağlarının çok daha iyi bir tahmin yaptığı gözlemlenmiştir.

Yapılan talep tahminiyle işletmenin ERP sisteminde biriken satış verileri zamansal olarak gözler önüne serilmiştir. Talep tahmininin uygulama sonuçları, üretim planlama, finansal planlama, işgücü planlaması ve karar vermede girdi olarak kullanılabilir. Örneğin; manifold gurubu ürünler için oluşturulacak satın alma siparişleri için adet belirlenmeden önce aylık tahmin sonuçlarına göre hareket edilebilir, ya da aylık ve yıllık satış verileri ve yapılan tahminler incelenerek manifold gurubu ürünleri işleyen makinelerin yeterli olup olmadığı, yeterliyse makinelerin bazılarının gruplanarak diğer ürün gruplarına tahsis edilebileceği, yeterli değilse gelecekte ne kadar makineye ihtiyaç duyulacağı, gibi konularda iş tahminleri



yapılabilir. İşletmenin ürettiği diğer ürün gurupları için de talep tahmini yapılarak planlar oluşturulabilir.

Ürünlere olan talepler ülkeden ülkeye ya da müşteriden müşteriye değişiklik göstermektedir. Müşterilerin yapısını, büyüklüğünü ve sipariş verirken hangi şartlar altında sipariş verdiklerini iyi anlamak şüphesiz talep tahminlerini daha sağlıklı yapmak açısından çok önemlidir. Bu nedenle yapılan bu çalışmayı daha ileri seviyelere taşımak için talebi etkileyen sayısal verileri müşterilere uygulanan anketlerle ve pazar araştırmalarıyla destekleyerek uzman bir YSA ile talep tahmini yapılabilir. Nitel ve nicel yöntemlerin bir arada kullanıldığı melez yöntemlerle yapılan talep tahminleri çok daha fazla doğruluk gösterebilir.



## KAYNAKLAR

- [1] Ringwood, J.V., Bofelli D., Murray F.T. “Forecasting Electricity Demand on Short, Medium and Long Time Scales Using Neural Networks”, Kluwer Academic Publishers, 31: 129–147, 2001.
- [2] Alon, I., Qi M., Sadowski R.J. “Forecasting aggregate retail sales: a comparison of artificial neural networks and traditional methods”, Journal of Retailing and Consumer Services, 8: 147-156, 2001.
- [3] Frank, C., Garg A., Sztandera L., Raheja A. “Forecasting women’s apparel sales using mathematical modeling”, International Journal of Clothing Science and Technology, s. 107-125, 2003.
- [4] Adıyaman, F., “ Talep Tahmininde Yapay Sinir Ağlarının Kullanılması” . Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, İstanbul, 2007.
- [5] Çuhadar, M., Güngör, İ., Göksu, A. “ Turizm Talebinin Yapay Sinir Ağları İle Tahmini ve Zaman Serisi Yöntemleri İle Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama”, s. 99-114, 2009.
- [6] Yazıcıoğlu, N., “ Yapay Zekâ İle Talep Tahmini” . Yüksek Lisans Tezi. Uludağ Üniversitesi, Bursa, 2010.
- [7] Karahan, M., “İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu İle Ürün Talep Tahmini Uygulaması”. Doktora Tezi. Selçuk Üniversitesi, 2011.
- [8] Yücesoy, M., “ Temizlik Kağıtları Sektöründe Yapay Sinir Ağları İle Talep Tahmini”. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, İstanbul, 2011.

- [9] Serttaş, Z.S., “ Türkiye’de Perakende Sektöründe Talebi Etkileyen Etmenler Ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması” . Yüksek Lisans Tezi. Yıldız Teknik Üniversitesi, İstanbul, 2011.
- [10] Aktepe, A., Önsel Ç., Ersöz S. “An Artificial Neural Network Model on Welding Process Control of 155 mm. Artillery Ammunition” , International Advanced Technologies Symposium, 2011.
- [11] Kaynar, O., Taştan S., Demirkoparan F. “ Yapay Sinir Ağları İle Doğalgaz Tüketim Tahmini” , Atatürk Ü. İİBF Dergisi, 10. Ekonometri ve İstatistik Sempozyumu Özel Sayısı, 2011.
- [12] Sevgi, P., “Hazır Giyim Perakendeciliği Yapan Bir Firmada Yapay Sinir Ağları İle Satış Tahmini” . Yüksek Lisans Tezi. Yıldız Teknik Üniversitesi, İstanbul, 2012.
- [13] Boltürk, E., “Elektrik Talebi Tahmininde Kullanılan Yöntemlerin Karşılaştırılması” . Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, İstanbul, 2013.
- [14] Ballı, M.T., “ Yapay Sinir Ağları İle Talep Tahmini Ve Gıda Sektöründe Uygulaması” . Yüksek Lisans Tezi. Yıldız Teknik Üniversitesi, İstanbul, 2014.
- [15] Es, H.A., Kalender F.Y., Hamzaçebi C. “Yapay Sinir Ağları İle Türkiye Net Enerji Talep Tahmini”, Journal of the Faculty of Engineering and Architecture of Gazi University, s. 495-504, 2014.
- [16] Özüdođru A.G., Görener A. “ Sağlık Sektöründe Talep Tahmini Üzerine Bir Uygulama” , İstanbul Ticaret Üniversitesi Sosyal Bilimleri Dergisi, 27: s. 37-53, 2015.

- [17] Sarı, M., “Yapay Sinir Ağları Ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması” . Yüksek Lisans Tezi. Sakarya Üniversitesi, Sakarya, 2016.
- [18] Silva, N., Ferreira M., Silva C., Neto P. “Improving Supply Chain Visibility With Artificial Neural Networks”, *Procedia Manufacturing*, s. 2083-2090, 2017.
- [19] Merkuryeva, G., Valberga, A., Smirnov, A. “ Demand forecasting in pharmaceutical supply chains: A case study” , *Procedia Computer Science*, s. 3-10, 2018.
- [20] Türk, E., Kiani, F. “Yapay Sinir Ağları ile Talep Tahmini Yapma: Beyaz Eşya Üretim Planlaması için YSA Uygulaması” , İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 2019.
- [21] Archer, B., Demand Forecasting And Estimation. *Travel Tourism And Hospitality Research*, <https://www.cabdirect.org/cabdirect/abstract/19871847153> (Erişim Tarihi: 12.03.2019)
- [22] Persson, H., Wilhelmsson, E. “The Impact Of Omni-Channel Retailing On Demand Planning For New Products At IKEA” . Master Thesis. The University of Lund, Sweden, 2018.
- [23] <https://www.mbaknol.com/management-concepts/need-for-business-forecasting/> (Erişim Tarihi: 09.03.2019)
- [24] Ramachandran, S., Deveraj, R. Production Planning And Control. The University of Sathyabama, [http://airwalkbooks.com/images/pdf/pdf\\_52\\_1.pdf](http://airwalkbooks.com/images/pdf/pdf_52_1.pdf) (Erişim Tarihi: 08.02.2019)
- [25] Tanyaş, M., Baskak, M. Üretim Plânlama ve Kontrol, 5. Baskı , İrfan Yayıncılık, İstanbul, 2013.

- [26] Karaibrahim, M., “ Yedek Parça Tedariğinde Kullanılabilecek Talep Tahmini Yöntemlerinin İncelenmesi: Bir İşletme Uygulaması” . Yüksek Lisans Tezi. Dokuz Eylül Üniversitesi, İzmir, 2016.
- [27] Bolt, G., Market And Sales Forecasting: A Total Approach, <http://feminineinquiry.com/market-and-sales-forecasting-a-total-approach-download-books-safe-gordon-j-bolt-1.pdf> (Erişim Tarihi: 15.03.2019)
- [28] Eski, H., Armaneri, Ö. Mühendislik Ekonomisi, Gazi Kitabevi, Ankara, 2006.
- [29] Armstrong, J.S., Green K.C. Demand Forecasting: Evidence-Based Methods, <http://forecastingprinciples.com/paperpdf/DemandForecasting.pdf> (Erişim Tarihi: 16.03.2019)
- [30] Reinert, G. Time Series , Hilary Term , 2010. <http://www.stats.ox.ac.uk/~reinert/time/notesht10short.pdf> (Erişim Tarihi: 16.03.2019)
- [31] Hyndman, R.J., Athanasopoulos, G. Forecasting: Principles and Practice. The University of Australia, <https://otexts.com/fpp2/> (Erişim Tarihi: 20.03.2019)
- [32] Yaffee, R. Introduction To Time Series Analysis and Forecasting With Applications Of Sas And SPSS, The University of New York, <https://faculty.psau.edu.sa/filedownload/doc-12-pdf-0a64dcdbc89c8d0f1540e08ec12091-original.pdf> (Erişim Tarihi: 20.03.2019)
- [33] [https://link.springer.com/referenceworkentry/10.1007%2F1-4020-0612-8\\_409](https://link.springer.com/referenceworkentry/10.1007%2F1-4020-0612-8_409) , (Erişim Tarihi: 25.03.2019)
- [34] <http://www.istatistik.gen.tr/?p=83> (Erişim Tarihi: 25.03.2019)

- [35] Duru, Ö., “ Zaman Serileri Analizinde Arıma Modelleri Ve Bir Uygulama” . Yüksek Lisans Tezi. İstanbul Üniversitesi, İstanbul, 2007.
- [36] Jere S., Moyo E. “ Modelling Epidemiological Data Using Box-Jenkins Procedure” , Open Journal of Statistics, 6: 295-302, 2016.
- [37] Özek, T. “ Zaman Serisi Modelleri Üzerine Bir Simülasyon Çalışması” . Yüksek Lisans Tezi. Selçuk Üniversitesi, Konya, 2010.
- [38] Frank, C., Vemulapalli, B., Sztandera, M., Raheja, A. Forecasting Women’s Apparel Sales Using Mathematical Modeling, The University of Philadelphia, <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.587.5662&rep=rep1&type=pdf> (Erişim Tarihi: 27.03.2019)
- [39] Konica, J.A., Hanelli, L. “Forecasting Next-Day the Electricity Demand Based On Fuzzy Logic Method Case for Albania” , Journal of Multidisciplinary Engineering Science and Technology (JMEST) , 2016.
- [40] <https://www.maplesoft.com/applications/view.aspx?SID=1409&view=html> (Erişim Tarihi: 02.04.2019)
- [41] Öztemel, E. Yapay Sinir Ağları, 4. Basım , Papatya Yayıncılık, İstanbul, 2016.
- [42] Ersöz, S., Ersöz, O.Ö. İşletmelerde Bilgi Sistemleri, 1. Basım, Nobel Yayıncılık, Ankara, 2015.
- [43] <https://data-flair.training/blogs/artificial-neural-network-applications/> (Erişim Tarihi: 10.04.2019)
- [44] <https://www.upgrad.com/blog/neural-networks-applications-in-the-real-world/> (Erişim Tarihi: 10.04.2019)

- [45] <http://www.alyuda.com/products/forecaster/neural-networkapplications.htm>  
(Eriřim Tarihi: 10.04.2019)
- [46] Kriesel, D. A Brief Introduction to Neural Network,  
[http://www.dkriesel.com/en/science/neural\\_networks](http://www.dkriesel.com/en/science/neural_networks) (Eriřim Tarihi:  
11.04.2019)
- [47] Fausett, L. Fundamentals of Neural Networks,  
[http://dl.matlabayar.com/siavash/Neural%20Network/Book/Fausett%20L.-  
Fundamentals%20of%20Neural%20Networks %20Architectures,%20Algorit  
hms,%20and%20Applications%20%281994%29.pdf](http://dl.matlabayar.com/siavash/Neural%20Network/Book/Fausett%20L.-Fundamentals%20of%20Neural%20Networks%20Architectures,%20Algorithms,%20and%20Applications%20%281994%29.pdf) (Eriřim Tarihi:  
12.04.2019)
- [48] <https://hmkcode.github.io/ai/backpropagation-step-by-step> (Eriřim Tarihi:  
14.04.2019)
- [49] [https://www.statista.com/statistics/280345/global-construction-machinery-  
market-size-by-region/](https://www.statista.com/statistics/280345/global-construction-machinery-market-size-by-region/) (Eriřim Tarihi: 17.02.2019)
- [50] [https://www.oemoffhighway.com/market-analysis/article/12176882/global-  
construction-and-mining-equipment-market-2016-outlook](https://www.oemoffhighway.com/market-analysis/article/12176882/global-construction-and-mining-equipment-market-2016-outlook)
- [51] [http://www3.tcmb.gov.tr/enflasyoncalc/enflasyon\\_anayeni.php](http://www3.tcmb.gov.tr/enflasyoncalc/enflasyon_anayeni.php) (Eriřim Tarihi:  
24.02.2019)
- [52] <https://www.muhasebenews.com/ortalama-doviz-kuru-programi/> (Eriřim  
Tarihi: 27.02.2019)