



ANKARA
HACI BAYRAM VELİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**YAPAY SİNİR AĞLARI YÖNTEMİ İLE TALEP TAHMİNİ VE
AYAKKABI SEKTÖRÜNE UYGULAMASI**

Deniz KORKUT

Tez Danışmanı

Prof. Dr. Murat ATAN

YÜKSEK LİSANS TEZİ

EKONOMETRİ ANABİLİM DALI

UYGULAMALI YÖNEYLEM ARAŞTIRMASI BİLİM DALI

AĞUSTOS 2019

**YAPAY SINIR AĞLARI YÖNTEMİ İLE TALEP TAHMİNİ VE AYAKKABI
SEKTÖRÜNE UYGULAMASI**

Deniz KORKUT

**YÜKSEK LİSANS TEZİ
EKONOMETRİ ANABİLİM DALI
UYGULAMALI YÖNEYLEM ARAŞTIRMASI BİLİM DALI**

**ANKARA HACI BAYRAM VELİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

AĞUSTOS 2019

Deniz KORKUT tarafından hazırlanan “YAPAY SİNİR AĞLARI YÖNTEMİ İLE TALEP TAHMİNİ VE AYAKKABI SEKTÖRÜNE UYGULAMASI” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Ankara Hacı Bayram Veli Üniversitesi, Lisansüstü Eğitim Enstitüsü, Ekonometri Anabilim, Uygulamalı Yöneylem Araştırması Bilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

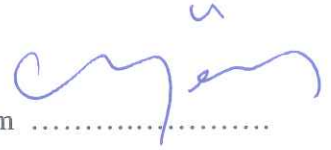
Danışman: Prof. Dr. Murat ATAN
Ekonometri, Ankara Hacı Bayram Veli Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum



Başkan: Doç. Dr. Atilla Gökçe
Ekonometri, Ankara Hacı Bayram Veli Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum



Üye: Prof. Dr. Murat ATAN

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum



Üye: Dr. Öğretim Üyesi İsmailoğlu

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum



Tez Savunma Tarihi: 08.AĞUSTOS.2019

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

Prof. Dr. Figen ZAİF
Lisansüstü Eğitim Enstitüsü Müdürü



ETİK BEYAN

Ankara Hacı Bayram Veli Üniversitesi Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Deniz KORKUT

08.08.2019



YAPAY SİNİR AĞLARI YÖNTEMİ İLE TALEP TAHMİNİ VE AYAKKABI SEKTÖRÜNE
UYGULAMASI
(Yüksek Lisans Tezi)

Deniz KORKUT

ANKARA HACI BAYRAM VELİ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Ağustos 2019

ÖZET

Perakende sektöründe hizmet veren işletmeler için geleceği öngörebilmek büyük önem arz etmektedir. Bu nedenle yapılacak olan tahmin çalışması işletmelere gelecek dönemleri hakkında önemli bilgiler vererek geleceği daha görebilmeleri ve atılımlarını bu yönde geliştirmelerinde kolaylık sağlayacaktır. Ters durumlarında ise karşılaşılabilecek en ufak bir beklenmedik durumda büyük kayıplar yaşamalarına sebep olabilir. Bu nedenle amacına uygun olarak planlanan bir tahmin çalışması ile birlikte işletmeler verecekleri kararların ardından başarılı sonuçlar elde edebileceklerdir. Bu çalışmada ayakkabı sektöründe hizmet veren işletmeye ait geçmiş dönem satışları dikkate alınarak gelecek dönemde gerçekleşecek satış değerlerine ulaşılması amaçlanmıştır. Problemin çözümü için satışları etkileyen değişkenler belirlenip bir sonraki yılın satış değerlerine ulaşılmıştır. Problemin çözümünde Matlab programının yapay sinir ağları algoritması kullanılmıştır. Sonuç olarak tahmini yapılan yıla ait değerlerin gerçek değerlere yakın olduğu gözlemlenmiştir.

Bilim Kodu : 112304
Anahtar Kelimeler : Yapay Sinir Ağları, Satış Tahmini, MATLAB
Sayfa Adedi : 51
Danışman : Prof. Dr. Murat ATAN

DEMAND FORRECASTING WITH ARTIFICIAL NEURAL NETWORKS METHOD AND
IMPLEMENTATION IN THE SHOE INDUSTRY

(M. Sc. Thesis)

Deniz KORKUT

ANKARA HACI BAYRAM VELİ UNIVERSITY
GRADUATE SCHOOL OF EDUCATIONAL SCIENCES

August 2019

ABSTRACT

For those businesses which serve in retail sector, it is very essential to predict the future. For this reason, the forecasting study will provide important information about the future periods to the enterprises so that they can see the future better and improve their breakthroughs in this direction. Otherwise, it may cause them to lose big under the unexpected situations. That's why, enterprises will achieve successful results after their decisions with a prediction study planned in accordance with their purpose. In this study, it is aimed to reach the sales values to be realized in the future by taking into consideration the past sales of the company serving in the shoe sector. In order to solve the problem, variables affecting sales were determined and the sales values of the following year were reached. In the solution of the problem, artificial neural network algorithm of Matlab program is used. As a result, it is observed that the values of the estimated year are close to the real values.

Science Code : 112304

Key Words : Artificial Neural Network, Sales Forecast, MATLAB

Page : 51

Supervisor : Prof. Dr. Murat ATAN

TEŐEKKÜR

Bu alıőmanın hazırlanmasında yardımını ve desteęini esirgemeyen her zaman sabır ve anlayıő gösteren sayın hocam Prof. Dr. Murat ATAN 'a sonsuz teőekkürlerimi sunarım. Ayrıca bana olan desteęini hi esirgemeyen arkadaőım Yasemin AKCAN'a , aileme ve bu alıőmada emeęi geen sevdiklerime ok teőekkür ederim.

Deniz KORKUT

İÇİNDEKİLER

| | Sayfa |
|---|--------------|
| ÖZET | iv |
| ABSTRACT..... | v |
| TEŞEKKÜR..... | vi |
| İÇİNDEKİLER | vii |
| ÇİZELGELERİN LİSTESİ..... | x |
| ŞEKİLLERİN LİSTESİ | xi |
| KISALTMALAR | xiii |
| 1. GİRİŞ | 1 |
| 2. TALEP TAHMİNİ..... | 3 |
| 2.1. Talep Tahminin Önemi | 4 |
| 2.2. Tahmin İlkeleri..... | 5 |
| 2.3. Talep Tahmin Yöntemleri | 6 |
| 2.3.1. Nitel Yöntemler | 7 |
| 2.3.1.1. Uzman Görüşünün Alınması | 7 |
| 2.3.1.2. Anket Yöntemi..... | 7 |
| 2.3.1.3. Delphi Tekniği | 7 |
| 2.3.1.4. Pert Yöntemi | 8 |
| 2.3.2. Nicel Yöntemler | 9 |
| 2.3.2.1. Hareketli Ortalamalar Yöntemi | 9 |
| 2.3.2.2. Üssel Düzeltme Yöntemi..... | 9 |
| 2.3.2.3. Regresyon Yöntemi | 10 |
| 2.3.2.4. Korelasyon Yöntemi..... | 10 |
| 2.3.2.5. Box Jenkins Yöntemi..... | 11 |
| 2.3.2.5.1. Otoregresif Modeller – AR(p) Modelleri..... | 12 |
| 2.3.2.5.2. Hareketli Ortalamalar – MA(q) Modelleri..... | 12 |

| | Sayfa |
|---|--------------|
| 2.3.2.5.3. Otoregresif Hareketli Ortalama Yöntemi – ARMA..... | 13 |
| 2.4. Talep Tahmin Aşamaları..... | 13 |
| 2.4.1. Talebi Etkileyen Etkenlerin Belirlenmesi | 13 |
| 2.4.1.1. Verilerin Toplanması | 13 |
| 2.4.1.2. Talep Tahmin Periyodunun Tespiti | 14 |
| 2.4.1.3. Tahmin Yönteminin Seçimi..... | 14 |
| 2.4.1.4. Tahmin Sonuçlarının Geçerliliğinin Araştırılması | 14 |
| 3. YAPAY SİNİR AĞLARI | 15 |
| 3.1. Yapay Sinir Ağlarının Tanımı..... | 15 |
| 3.2. Yapay Sinir Hücresinin Tarihçesi | 15 |
| 3.3. Yapay Sinir Ağları ile ilgili Temel Kavramlar | 16 |
| 3.4. Biyolojik Yapay Sinir Hücresi | 16 |
| 3.5. Yapay Sinir Hücresi | 17 |
| 3.5.1. Girdiler | 18 |
| 3.5.2. Ağırlıklar | 18 |
| 3.5.3. Toplama Fonksiyonu | 18 |
| 3.5.4. Aktivasyon Fonksiyonu..... | 19 |
| 3.6. Yapay Sinir Ağlarının Avantajları | 20 |
| 3.7. Yapay Sinir Ağlarının Dezavantajları | 21 |
| 3.8. Mimari Yapılarına Göre Yapay Sinir Ağları | 21 |
| 3.8.1. İleri Beslemeli Ağları | 21 |
| 3.8.2. Geri Beslemeli Yapay Siniri Ağları | 22 |
| 3.9. Yapay Sinir Ağlarında Öğrenme Algoritmaları | 23 |
| 3.9.1. Danışmanlı Öğrenme Yöntemi..... | 24 |
| 3.9.2. Danışmansız Öğrenme Yöntemi..... | 24 |
| 3.9.3. Takviyeli Öğrenme Yöntemi..... | 25 |

| | Sayfa |
|--|--------------|
| 3.9.4. Karma Stratejiler Yöntemi | 25 |
| 3.10. Yapay Sinir Ağlarında Öğrenme Kuralları | 25 |
| 3.10.1. Hebb Kuralı | 26 |
| 3.10.2. Hopfield Öğrenme Kuralı..... | 26 |
| 3.10.3. Kohonen Öğrenme Kural | 26 |
| 3.10.4. Delta Öğrenme Kuralı | 27 |
| 3.11. Yapay Sinir Ağlarında Çok Katmanlı ve Geri Beslemeli Algoritmalar..... | 27 |
| 3.12. Çok Katmanlı yapay Sinir Ağlarının Çalışma Prosedürü | 27 |
| 4. UYGULAMA | 29 |
| 4.1. Amaç ve Kapsamı | 29 |
| 4.2. Talep Tahmin Probleminin Tanımlanması..... | 29 |
| 4.3. Yapay Sinir Ağı Mimarisi | 34 |
| 4.4. Yapay Sinir Ağlarının Matlab Uygulaması..... | 34 |
| 4.5. Model Parametrelerinin Belirlenmesi | 35 |
| 4.6. Yapay Sinir Ağlarının Eğitilmesi | 37 |
| 4.7. Sonuçların Test edilmesi | 41 |
| 4.8. Yapay Sinir Ağları ile Satış Tahmini | 43 |
| 5. SONUÇ VE DEĞERLENDİRME..... | 47 |
| KAYNAKLAR | 49 |
| ÖZGEÇMİŞ | 51 |

ÇİZELGELERİN LİSTESİ

| Çizelge | Sayfa |
|---|-------|
| Çizelge 2.1. Regresyon Katsayısı Değer Aralıkları | 11 |
| Çizelge 3.1. Biyolojik Sinir Hücresi ile YSA Hücresinin Karşılaştırılması | 18 |
| Çizelge 4.1. Momentum Katsayısının Belirlenmesi | 36 |
| Çizelge 4.2. Öğrenme Katsayısının Belirlenmesi | 36 |
| Çizelge 4.3. Nöron Sayısının Belirlenmesi | 37 |
| Çizelge 4.4. YSA Parametrelerinin Belirlenmesi | 37 |
| Çizelge 4.5. Öğrenme Sonrası Tahmin ve Gerçekleşen Değerlerin Karşılaştırılması..... | 42 |
| Çizelge 4.6. 2019 Yılına Ait Girdi Verileri | 44 |
| Çizelge 4.7. 2019 Yılına ait Satış Tahmin Değerleri | 45 |

ŞEKİLLERİN LİSTESİ

| Şekil | Sayfa |
|---|-------|
| Şekil 2.1. Tahmin Yöntemlerinin Sınıflandırılması..... | 6 |
| Şekil 2.2. İhtimal Dağılım Eğrisi | 8 |
| Şekil 2.3. Box - Jekins Tahmin Aşamaları | 12 |
| Şekil 3.1. Biyolojik Sinir Hücresi | 17 |
| Şekil 3.2. Yapay Sinir Ağın Tasarımı | 17 |
| Şekil 3.3. Yapay Sinir Ağlarına ait Aktivasyon Fonksiyonu..... | 20 |
| Şekil 3.4. İleri Beslemeli Çok Katmanlı Yapay Sinir Ağları..... | 22 |
| Şekil 3.5. Geri Beslemeli Ağ Modeli..... | 23 |
| Şekil 3.6. Danışmanlı Öğrenme Algoritması | 24 |
| Şekil 3.7. Takviye Öğrenme Yöntemi | 25 |
| Şekil 4.1. Toplam Stok – Satış Grafiği | 30 |
| Şekil 4.2. Toplam Satış – Müşteri Giriş Sayısı Karşılaştırılması | 31 |
| Şekil 4.3. Toplam Satış – SKU Sayısı Karşılaştırılması..... | 32 |
| Şekil 4.4. Toplam Satış – Mevsim Sıcaklık Değerleri Karşılaştırılması | 33 |
| Şekil 4.5. Toplam Satış – Ortalama Fiyat Karşılaştırması..... | 33 |
| Şekil 4.6. Bağımlı ve Bağımsız Değişkenlerinin Matlab’a Tanıtılması | 38 |
| Şekil 4.7. Girdi ve Çıktı Değerlerinin Sınıflandırılması | 38 |
| Şekil 4.8. Girdi ve Çıktı Değişkenlerine Ait Parametreler | 39 |
| Şekil 4.9. Yapay Sinir Ağı Model Gösterimi..... | 39 |
| Şekil 4.10. Matlab Yapay Sinir Ağı Eğitim Ekranı | 40 |
| Şekil 4.11. YSA Eğitim Sonrası Performans Grafiği | 40 |
| Şekil 4.12. Eğitim Sonrası Öğrenme, Doğrulma, Test Kümelerine İlişkin Regresyon Grafiği | 41 |
| Şekil 4.13. Matlab YSA Giriş Ekranı | 42 |
| Şekil 4.14. YSA İle Bulunan Tahmini Değerler İle Gerçek Değerlerin Grafik Gösterimi | 43 |

| Şekil | Sayfa |
|---|--------------|
| Şekil 4.15. YSA İle 2019 Yılına Ait 12 Aylık Veri İçin Tahmin Değerleri Test Aşaması..... | 44 |
| Şekil 4.16. Gerçekleşen Satış ve Tahmini Satış Değerlerinin Karşılaştırması | 45 |



KISALTMALAR

Bu çalışmada kullanılmış kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

| Kısaltmalar | Açıklamalar |
|--------------------|--------------------|
| RPT | Replenishment |
| SKU | Model Sayısı |
| YSA | Yapay Sinir Ağları |



1. GİRİŞ

Günümüzde işletmeler hızlı bir şekilde artan ve tahmini zorlaşarak ilerleyen piyasa koşullarında sürdürülebilirliklerini devam ettirebilmeleri için karşılaştıkları ve karşılaşılabilecekleri tüm sorunlara hızlı ve etkin bir çözüm yolu bulmak zorundadırlar. İşletmeleri bu konuda en çok zorlayan sorun ise piyasada meydana gelebilecek ani bir değişim karşısında nasıl bir yol izlemek gerektiğinin kararının verilmesidir. Bu konuda bir çok işletme kendilerine yol gösterebilecek doğru kararlar vermek zorundadır. Bu sorunun çözümü olarak geliştirilen ve bir çok araştırmada kullanılan talep tahmin yöntemlerinden yararlanılmaktadır.

Günümüzde işletmelerin sürekli ve hızla değişen tüketici tercihlerinin ve teknolojik gelişmeler karşısında tahmin yapmasını zorlaştırmaktadır. Bu nedenle yapılmaya çalışılan talep tahminine dar kapsamda değil geniş açıdan bakılması gerekmektedir. Bu nedenle işletmelerin kendi içinde barındırdıkları departmanların (Üretim Planlama, Satın alma, Lojistik gibi) birbirleri arasındaki iletişimin güçlü olması gerekmektedir. Süreç içerisinde güçlü iletişim sayesinde işletme açısından en doğru kararın alınması ve çalışanların yapılan iş hakkında bilgilerinin olması sağlanacaktır. Bunun sonucunda işletme üzerinde çalıştığı işi doğru zamanda doğru kişilerle yapma imkanı bulacaktır.

Talep tahmini işletmelerin kısa ,uzun ve ani kararları almasında ve kendileri için en iyi sonuca ulaşmada kullanılacak yöntemlerin başında gelmektedir. Talep tahmini yapılmasında literatürde kullanılan bir çok yöntem bulunmaktadır. Son dönemlerde bu yöntemlerden biri olan sıkça talep tahmininde kullanılan yöntemlerden biri de biyolojik sinir sistemi örnek alınarak geliştirilen yapay sinir ağı modelidir. Yapay sinir ağları modelinin çıkış noktası insanların deneyimlerine dayanmaktadır. İnsanların yaşadıkları olaylar sonucunda elde ettikleri deneyimlerin sonrasında gelecekteki olaylar hakkında bir fikir sahibi olmaları ve atacakları adımları bu deneyimlerden elde ettikleri sonuçlarla bağdaştırmaktadırlar. Bu durumun bilgisayar ortamına aktarıldığında tıpkı bir insan beyni gibi sisteme aktarılan geçmiş verileri çeşitli yöntemlerle analiz ederek sonuçlar sunmaktadır. Burada alınan sonuçların anlamlı ya da anlamsız olması sisteme tanıtılan verilerin birbirleri ile ilişkisine doğrudan bağlıdır. Tanıtılan bilgiler istenilen sonuçla ne kadar çok alakalı ise bizlere o derece doğru sonuçlar sunmaktadır.

Çeşitli tahmin yöntemleri içerisinde yapay sinir ağları yöntemi gerçekleşen değerlere en yakın sonuçları vermesinden dolayı bir çok araştırmada kullanılan ve diğer tahmin

yöntemleri ile karşılaştırmaları yapılarak tahmin performansının yüksek olduğu kanıtlanmaya çalışılmıştır.

Tez çalışmasında Türkiye’de yaklaşık olarak her ilde mağazası bulunan ve ayakkabı sektöründe hizmet veren işletmeye ait veriler kullanılarak gelecekteki satış verileri tahmin edilmeye çalışılmıştır.

Türkiye’de ayakkabı sektöründe hizmet veren küçük veya büyük bir çok işletme bulunmaktadır. Bu sektörün içerisinde bulunan işletmelerin ayakta kalabilmesi için talep tahminlerini gerçeğe en yakın şekilde tahmin etmesi gerekmektedir. İşletmenin müşterilerine sunduğu ürünler hakkında bir çok araştırma yapıp satış potansiyelini ve gelecekteki durumunu en iyi şekilde analiz etmesi gerekmektedir.

Tez çalışmasının ilk bölümünde talep tahminin tanımı yapılmış ve çeşitli yöntemlerden bahsedilmiştir. İkinci bölümünde ise talep tahmini uygulamasında kullanılan yapay sinir ağları modeli hakkında ayrıntılı bilgiler verilmiştir. Burada yapay sinir ağları yöntemi kullanılırken dikkat edilmesi gereken detaylar hakkında bilgi verilmiştir.

Tez çalışmasının son bölümü olan üçüncü bölümde ise yukarıda da bahsedilen Türkiye’de 517 yurt dışında 80 mağazası bulunan ve ayakkabı sektöründe hızla gelişen bir işletmeye ait gerçek veriler kullanılarak talep tahmini yapılmıştır. Çalışma İstanbul bölgesinde pilot olarak seçilen 15 mağazanın Spor ayakkabı kategorisinde bulunan satışları tahmin edilmiştir. Bu tahmin çalışması yapılırken yapay sinir ağları modeline ait ileri beslemeli geri yayımlı modeli kullanılmıştır.

2. TALEP TAHMİNİ

Tahmin akıl ve mantık ilkelerine dayanarak gelecekte karşılaşılma olasılığı muhtemel olayların önceden kestirilmesidir. Geleceğin bilinmemesi ve bunu tahmin etmeye çalışmak günümüz piyasasında önemli bir unsurdur. Tüm özel ya da kamu kuruluşlarının kendilerini geliştirebilmeleri adına ve gelecek zamanda mevcut durumlarını koruyabilmeleri iyi bir şekilde tasarlanmış plan ile mantıklı çözümler bularak ve bu çözümleri gerçek hayatta uygulamalıdır. İşletmeler geleceğe yönelik karar verirken, doğru ve sağlam temellere dayalı tahminlere ihtiyaçları vardır. Doğru olmaya ve gerçek temellere dayanmayan tahminler işletmenin hedeflerini olumsuz yönde etkilemektedir. Bu olumsuzluklar işletmenin pazar kaybına ya da pazardan çekilmesine neden olabilir (Çağlar, 2007:46) .

Tahmin, geçmiş verileri kullanarak gelecekte işletmenin karşılaşabileceği olası süreci göstermektedir. Tahmin aslında gerçek olayların basit bir kopyası olarak değerlendirilir. Bu nedenler işletme için önemli bir süreçtir (Acar, 1994).

İşletmeler karşılaştıkları sorunlar karşısında başarısız olmamak için bir çok tahmin yönteminden yararlanırlar ve bu şekilde müşterilerine daha iyi hizmet vererek piyasada prestijli işletmeler arasında değerlendirilecektir (Efendigil, 2008)

Talep tahmini, işletmelerin hizmet verdiği ürünleri yılın hangi dönemlerinde piyasaya sürmelerini ve üretilen ürünlerin ne kadarının ilk aşamada ne kadarının daha sonra üretilmesi gerektiği konusunda bilgi vererek işletmelerin kısa dönemli üretim ve dağıtım sürecini belirlemektedir. Yapılan tahminin her zaman kesin sonuçlar vermeyeceği her tahmin modelinde bir hata payının olma olasılığı akıllardan çıkarılmamalıdır (Bolt, 1994).

İşletmelerin sürdürülebilirliklerini devam ettirebilmeleri açısından yaptıkları tahmin işletmenin gelecek dönemde mevcut konumunu sürdürebilmesi için stratejik öneme sahiptir. Yapılan bu tahminler işletmelere ve işletmede görev alan kişilere aldıkları kararlarda önemli bilgiler vererek yardımcı olacaktır. İşletmelerin geleceğe yönelik aldıkları kararlarda gerçeğe en yakın ve güvenilir tahminlere ihtiyaçları vardır. Yöneticilerin doğru karar vermesini sağlayan bu tahminler yapılırken alınan kararlarda doğrudan etkisi olan ve konular hakkında yoğunlaşmak durumundalardır. Ana konu hakkında dolaylı yönden etkisi olan konular hem zaman kaybına hem de gereksiz bilgi birikimine neden olacaktır.

Tahmin yaparken dikkat edilmesi gereken unsurlar bulunmaktadır. Bunlar tahmin sürecinin zaman aralığı, tahmin yapan kişinin hataları tolere edebileceği hata payı, modelin anlamlılığı gibi bir çok dikkat edilmesi gereken unsurlar bulunmaktadır (Sertaş, 2011).

Talep tahmin yönteminde üç tür yöntem kullanılmaktadır. Bu yöntemler kantitatif, kalitatif ve yapay zeka tabanlı yöntemlerdir. Son dönemlerde teknolojinin gelişmesiyle birlikte yapay zeka tabanlı yöntemlerde kullanılmaya başlanılmıştır. Kalitatif yöntemlerin temeli ise genellikle kişisel deneyimlere dayanırken, kantitatif yöntemler genellikle istatistiksel yöntemleri temel almaktadır (Olgun, 2009).

Talep tahmini dört farklı zaman aralığında incelenir. Bu zaman aralıkları aşağıda belirtilmektedir (Yazıcıoğlu, 2010) .

Çok Kısa süreli tahmin: Günlük – haftalık,

Kısa süreli tahminler: 1 Hafta – 6 ay,

Orta süreli tahminler: 6 ay – 5 yıl,

Uzun süreli tahminler: 5 yıl +

Talep Tahmini yaparken yukarıda sıralanan dört farklı zaman aralığının ortak amacı geleceği öngörebilmektir. Fakat tahminlerin gerçeğe yakın oranları birbirlerinden çok farklı sonuçlar vermektedir. Kısa süreli tahminlerde kullanılan veri aralığı kısıtlı olduğundan dolayı bu zaman aralığında yapılan tahminler uzun dönemli tahminlere göre gerçekleşme olanağı her zaman daha fazladır.

2.1. Talep Tahminin Önemi

Talep tahmini, tüketicilerin kısa veya uzun vadede taleplerinin ne yönde olması gerektiğinin belirlenmesi yöntemidir. Bu tahmin aynı zamanda işletmenin hizmet verdiği ürün grubunun üzerinde yoğunlaşması ve hangi ürünü hangi miktarda ne zaman üretmesi gerektiği konusunda işletmeye yön vermektedir.

İşletmeler için gelecekte talebin hangi aşamada olacağını talep tahmin yöntemi ile tahmin edilmesi büyük önem arz etmektedir. Talep tahminin doğru tahmin edilmesi özellikle üretim planlaması açısından stratejik bir öneme sahiptir (Top & Yılmaz , 2009). Talep tahmininde meydana gelebilecek ve sonuca direkt etki ederek hatalı sonuçlara yönlendirerek başarısız bir tahmin sonucu ile karşılaşmak mümkündür. Bunlarda ilki üretilmesi planlanan ürün gereğinden fazla üretilebilir ya da diğeri ise yanlış talep tahmini yaparak hiç talep görmeyecek ürünü üretebiliriz. Bu durum işletme açısından büyük bir depolama maliyeti

ortaya çıkarmaktadır. Meydana gelebilecek aksaklıklardan biri olan talep fazlalığı veya eksikliği özellikle işletmenin tam anlamıyla doğru bir piyasa araştırması yapmamış olmasının kötü sonuçlarından biridir. İşletmelerin tam doğru talep tahmini yapmamış olması ve bunun sonucu olarak talep eksikliği ile karşılaşılması işletmelerin iflasıyla sonuçlanabilecek durumlara yol açmaktadır. İşletmelerin iflası sadece işletmenin kapatılması olmaktan ziyade bir çok çalışanın işsiz kalmasına neden olacaktır. Bu da milli ekonomiyi kötü etkilemiş olacaktır. Üretim eksikliği olduğu durumlarda ise söz konusu mal ithal edilmek durumu da kalındığından dolayı malın fiyatının artmasına neden olacaktır (Meydan, 2007).

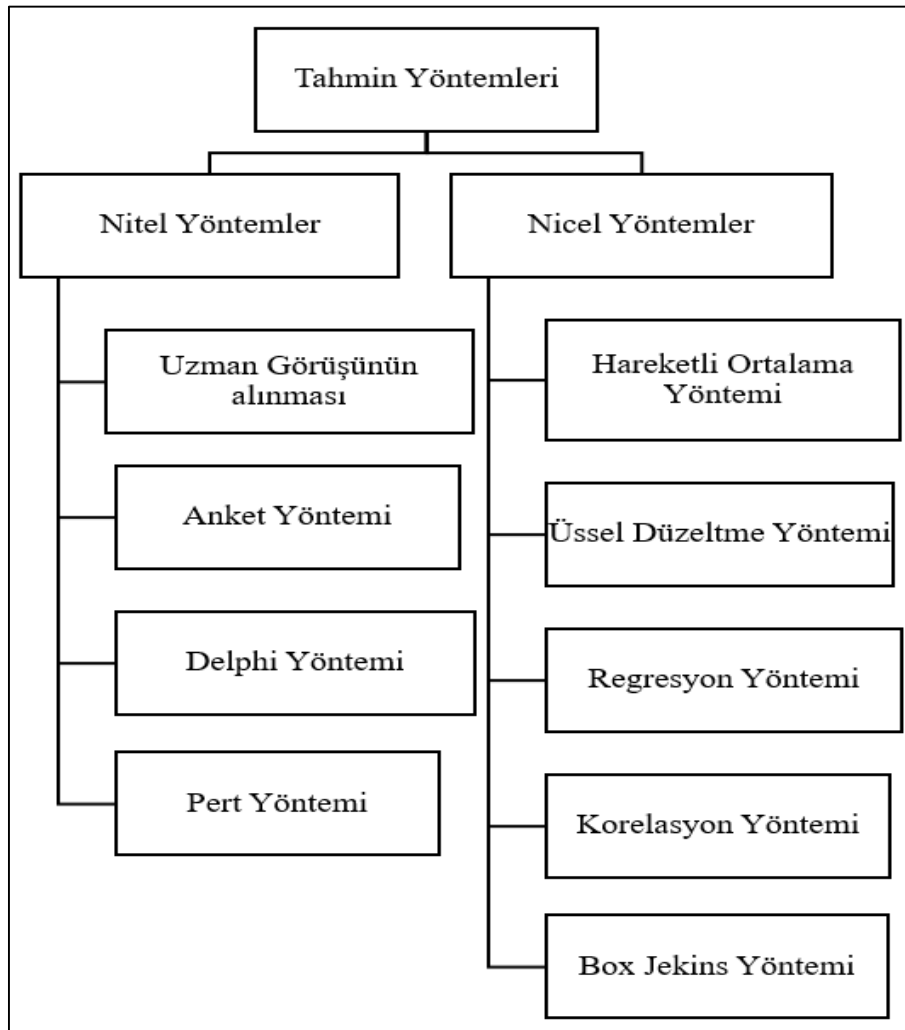
2.2. Tahmin İlkeleri

Tahmin yöntemlerinin kullanımını için tahmin ilkelerinin bilinmesi gerekir. Tahmin ilkeleri aşağıdaki gibi belirtilmiştir (Üreten, 2005).

- Tahmin yapılırken genellikle ulaşmak istenen sonuç ile gerçekleşen sonuç arasında farklılıklar bulunmaktadır. Bu sonucu ortaya çıkaran sebeplerden biri tahmini etkileyecek tüm değişkenlerin göz önünde bulundurulmaması, diğeri ise hiçbir zaman tahmin edilemeyen olası durumların ortaya çıkmasıdır.
- Yapılan tahminlerin hatalarının olasılıklarının bilinmesi önemlidir. Bu durumda tek bir hata oranı belirlemek yerine hata oranı için bir aralık belirlenmesi tahmin için uygun bir süreç olacaktır.
- Tahmini yapılan konu için elde edilen örneklemelerin zaman aralığı uzun olmalıdır. Çünkü kısa dönemde yapılan tahminlerin gerçekleşme olasılığı uzun dönemlerde yapılan tahminlerin gerçekleşme olasılığından daha fazla olduğu görülmüştür. Bunun asıl sebebi ise kısa dönemli yapılan tahminlerde belirsizlik oranı düşük olmasının sebebi ile hata oranı düşükken uzun dönemli tahminlerde hata oranı artmaktadır. Bu nedenler tahmin yapma sürecinin bir çok aşaması bulunmaktadır. Bunlar:
 - Tahminin amacının belirlenmesi,
 - Tahmin döneminin belirlenmesi,
 - Bir tahmin yönteminin seçilmesi,
 - Tahmin modelinin geçerliliğinin test edilmesi,
 - Oluşturulan modelin çözümlenmesi ve sonuçlarının değerlendirilmesi,
 - Sonuçların uygulanması ve izlenmesidir.

2.3. Talep Tahmin Yöntemleri

Nitel ve nicel yöntemler olarak talep tahmin yöntemleri 2 grupta incelenmektedir. Nitel tahmin yöntemleri sayısal değerlerin bulunmadığı bireysel deneyimlere göre karar verilmektedir. Nicel yöntemleri ise sayısal değerlerin bulunduğu geçmiş dönemlerden gözlenen verilerin çeşitli yöntemlerle analiz edilmesiyle elde edilen sonuçlardır. Nicel yöntemin kullanılmasına karar verildiğinde elde edilen veri sayısal bir değer olamaması ve geçmişe yönelik veri datasının olması gerekmektedir. Tahmin yöntemler aşağıda Şekil 2.1'deki gibi gösterilmektedir (Aydın, 2012).



Şekil 2.1. Tahmin Yöntemlerinin Sınıflandırılması

Kaynak: (Tokgöz , Helvacıoğlu, Karaatlı, & Ömürbek, 2012)

2.3.1. Nitel Yöntemler

Talep tahmininde nitel yöntemlerde bilimsel veriler ve sayısal değerler yerine kişisel deneyimlere dayanmaktadır. Bu nedenle bir çok tahmin yöntemlerine göre tahmin performansı daha düşüktür.

2.3.1.1. Uzman Görüşünün Alınması

Araştırmacının elinde yeterli sayısal verilerin bulunmadığı zamanlarda tahmin yapılacak konu üzerinde uzun süre çalışmış ve konu ile ilgili uzmanlaşmış kişilerin görüşlerine başvurularak yapılan tahin yöntemidir. Bu yöntem özellikle kısa süreli tahminlerinde kullanılması daha uygundur. Bu yöntem diğer tahmin yöntemleri ile karşılaştırıldığında hem avantajlı hem de dezavantajları vardır. Yöntemin avantajı kısa vadeli olduğundan dolayı çok kısa zamanda sonuca ulaşılabilir. Fakat sayısal verilere dayanmayıp kişilerin görüş ve düşüncelerinden yola çıkıldığı için hatalı sonuçlar verme olasılığının yüksek olmasından dolayı dezavantajları mevcuttur.

2.3.1.2. Anket Yöntemi

Anket yöntemi ile yapılan araştırmalarda araştırmacı geniş kitlelere çok rahat bir şekilde ulaşabilmektedir. Bu yöntem özellikle benzer sektörde üretim yapan işletmelerin yeni bir ürün üretmeden önce tüketicilerin ilgili ürüne verecekleri tepkiyi ölçmek adına sıkça kullanılmaktadır. Fakat bir önceki yöntem gibi anket yöntemin de kaynağı bilimsel verilerden dayanmayıp kişisel bilgi ve deneyimlere dayandığı için araştırmayı yapan kişileri hatalı sonuçlara yönlendirme olasılığı yüksektir.

2.3.1.3. Delphi Tekniği

Delphi tekniği ilk olarak 1950'li yılların başında ABD'de bir şirkette çalışan Olaf Helmer ve Norman Dalkey tarafından geliştirmeye çalışılmıştır. Delphi tekniği temel amacı geleceğe ilişkin tahminlerde bulunurken uzman görüşlerini ortaya çıkararak uzmanlaşmayı sağlamayı hedeflemektedir. Delphi yönteminin uygulanması şu şekilde gerçekleşmektedir. Konu ile ilgili uzmanlıkları olan katılımcılara art arda anketler uygulanarak anket sonuçları katılımcılar ile paylaşılmaktadır. Bu süreç uzmanların ortak bir sonuç elde edene kadar devam etmektedir. Bu yöntemde sayısal verilere dayanmadığından dolayı hata olasılığı yüksek tahmin yöntemlerinden biridir.


2.3.1.4. Pert Yöntemi

Pert yöntemi, ABD Deniz Kuvvetleri tarafından geliştirilmiş bir tahmin yöntemidir. Bu tahmin yöntemi her zaman belirli bir aralıkta ve olasılıkla ilgili bir yaklaşımdır.

Pert yönteminde üç senaryo geliştirilmiştir.

- **iyimser (İ)** – her şey sorunsuz uygulanacağına inanmak
- **gerçekçi (G)** – uygulamayı gerçekçi olarak değerlendirmek,
- **Kötümser (K)** – Tipik sorunları baz alarak kötümser düşünmek.

Pert yönteminde kullanılan dağılım aşağıdaki gibi gösterilmektedir. Bu eğri pert yönteminde “İhtimal Dağılım Eğrisi” olarak adlandırılmaktadır.



Şekil 2.2. İhtimal Dağılım Eğrisi

Kaynak: (Türkan, 2007)

İhtimaller Dağılım eğrisi belirli bir zaman aralığında problemin çözüm zamanını göstermektedir. İlgili problem çözümü normal şartlar altında gerçekleştiğinde t_m zamanında gerçekleşir. Problemin çözümü normal süreden daha kısa zamanda gerçekleşiyorsa en erken tanıma süresi olarak belirlenen t_a zamanında gerçekleşir. Problemin süresi normal şartlar altında en kötü ihtimalle gerçekleşmesi beklenen t_b zamanının da aşmışsa o zaman en geç tanıma süresinde gerçekleşmiş olacaktır.

2.3.2. Nicel Yöntemler

Nicel tahmin yöntemleri tahmine konusu geçmiş dönemde gerçekleşen değerler dikkate alınarak gelecek dönemlerin tahmin edilmesi yöntemidir. Nicel tahmin yöntemlerinde tahmini yapılan konu gelecekte vereceği tepki geçmişte verdiği tepki ile aynı yönde olduğu kabul edilir.

2.3.2.1. Hareketli Ortalamalar Yöntemi

Mevsimsellik nedeni ile talepte meydana gelen değişimlerin belirlenmesinde kullanılan bir yöntemdir. Örneğin geçmişteki satışların incelenmesi ile satış rakamlarının gösterdiği değişikliğe göre satış rakamları tahmin edilmektedir. Hareketli Ortalamalar Yöntemi ile 3 , 6 ,12 gibi aylık satış ortalamalarına göre tahminler yapılmaktadır (Tekin, 1996).

Zaman serisi analiz yöntemlerinden biri olan hareketli ortalamalar yönteminde talep tahmini yapılırken yakın geçmişten yararlanılmaktadır. Burada yapılan tahmin sadece aylık satış tahminleri yapılmaktadır.

Hareketli ortalamalar yöntemi ile tahminde bulunulurken yeni bulunan değerler her seferinde eski değerden çıkarılarak yeni dönem değer elde edilmektedir. Elde edilen yeni değerler ise bir sonraki tahmin edilecek dönemde tahmin değeri olarak kullanılır. Örneğin üç aylık hareketli ortalama ile Mayıs ayının satış değeri, Ocak , Şubat, Mart aylarına ait toplam satışlarının ortalaması alınarak bulunur (Üreten S. , 2005).

2.3.2.2. Üssel Düzeltme Yöntemi

Üssel düzeltme yöntemi, verilerdeki son değişim ve sıçramaları dikkate alarak tahminlerin ya da öngörülerin devamlı güncelleştirildiği bir yöntemdir. Hem deterministik hem de stokastik trende sahip olan serilere uygulanabilmektedir.

Üssel düzeltme yöntemi verilerdeki son değişim ve sıçramaları dikkate alarak tahminlerin sürekli güncelleştirildiği bir yöntemdir. Diğer tahmin yöntemlerine göre az sayıda verinin kullanılması gerektiğinden dolayı sıkça kullanılan bir metottur.

Üssel düzeltme yöntemi ile tahmin yapılırken çok az sayıda veri kullanılması gerektiğinden dolayı işletmeler açısından büyük kolaylık sağlamaktadır. Bu nedenle kullanımı geniş alanlara yayılmıştır. Bu yöntemin en büyük dezavantajı ise belli bir trende sahip olmasından kaynaklanmaktadır (Bal, 2015).

2.3.2.3. Regresyon Yöntemi

Regresyon analizi tahmin modelimizde kullanılan ve istenilen sonucu belirten bağımlı değişken ile bağımsız değişken arasındaki ilişkiyi inceleyen bir yöntemdir. Burada değişken sayısında göre farklı adlandırmalar yer almaktadır. Eğer oluşturulan regresyon modelinde tek değişken varsa buna **Tek Değişkenli Regresyon**, eğer modelde bağımlı değişkeni etkileyen birden fazla değişken varsa buna **Çok Değişkenli Regresyon Modeli** denilmektedir.

Doğrusal regresyon modelinde bağımlı değişken yalnızca bağımsız değişkenin fonksiyonu olduğundan aralarında doğrudan bir ilişki söz konusudur.

$$Y = \alpha + \beta X_i + \varepsilon \quad (2.1)$$

şeklinde bağımlı ve bağımsız değişkenleri içeren bir modeldir. Yukarıda yer alan örnek denklemde yer alan değerlerden biri olan Y tahmin değerini X_i ise bağımsız değişken olarak adlandırılmaktadır ve α değerleri ise denklemin X ekseninde kestikleri noktaları belirtmektedirler. ε değer ise ilgili denkleme ait hata değerlerini belirtmektedir.

2.3.2.4. Korelasyon Yöntemi

Korelasyon tanım olarak bir değişken değeri değişirken diğer değişkenin değeri de buna paralel olarak değişiyorsa korelasyon bağlantısı vardır denilmektedir. Korelasyon yöntemi iki değişken arasındaki ilişkinin derecesini ortaya çıkarmaktadır. Korelasyon yöntemini de her iki değişken arasındaki ilişkinin derecesini gösteren değere korelasyon kat sayısı denilmektedir. Korelasyon katsayısı [-1,1] aralıkları arasında yer almaktadır. Eğer korelasyon katsayısı +1 değerini yakınsama şeklinde ise iki değişken arasında pozitif doğrusal ilişki olduğunu, eğer -1 değerine yakınsıyorsa iki değişken arasında negatif doğrusal ilişki olduğu kabul edilmektedir. Pozitif veya negatif değerler dışında iki değişken arasında hiçbir ilişkinin olmadığı durumlar ile de karşılaşılabılır. Burada ise ilişki katsayısı 0 olarak belirlenir. Korelasyon Katsayısı değerleri aşağıda Çizelge 2.1'deki gibi yorumlanmaktadır.

Çizelge 2.1. Regresyon Katsayısı Değer Aralıkları

| Korelasyon Katsayı değerleri | Korelasyon değerleri |
|------------------------------|----------------------|
| 0.90- 1.00 | Yüksek |
| 0.70- 0.90 | Orta |
| 0.40 - 0.70 | Normal |
| 0.20- 0.40 | Düşük |
| 0.00 - 0.20 | Çok düşük |

2.3.2.5. Box Jenkins Yöntemi

George Box ve Gwilym Jenkins tarafından 1970'li yıllarda ortaya çıkmıştır. Bu yöntemin temelinde zaman serilerini sadece kendi içinde barındırdığı geçmiş değerleri ve olasılıksal hata terimleri ile açıklamaktadır.

Box-Jenkins metodu tek değişkenli bir model olup ve kısa zaman aralıklarını kapsayan tahminlerde başarılı sonuçlar vermektedir. Bu methodun en önemli varsayımlarından biri de serinin eşit zaman aralıkları ile belirlenen gözlem değerlerinden oluşması ve durağan ve kesikli bir seri olması gerekmektedir. Burada temel amaç az sayıda veri kullanılarak en iyi modelin oluşturulması hedeflenmektedir. Diğer iki tahmin modelinde bilgisayar yöntemi kullanıldığından dolayı müdahale imkanı olmadığı gibi bu modelde müdahale imkanı bulunmaktadır. Diğer modellere göre çözümlenmesi daha karmaşık bir yapıya sahiptir (Çağlar, 2007: 46).

Box Jenkins yönteminde üç modelleme türü bulunmaktadır. Bunlar aşağıda belirtilmektedir.

Otoregresif (AR) Süreç,

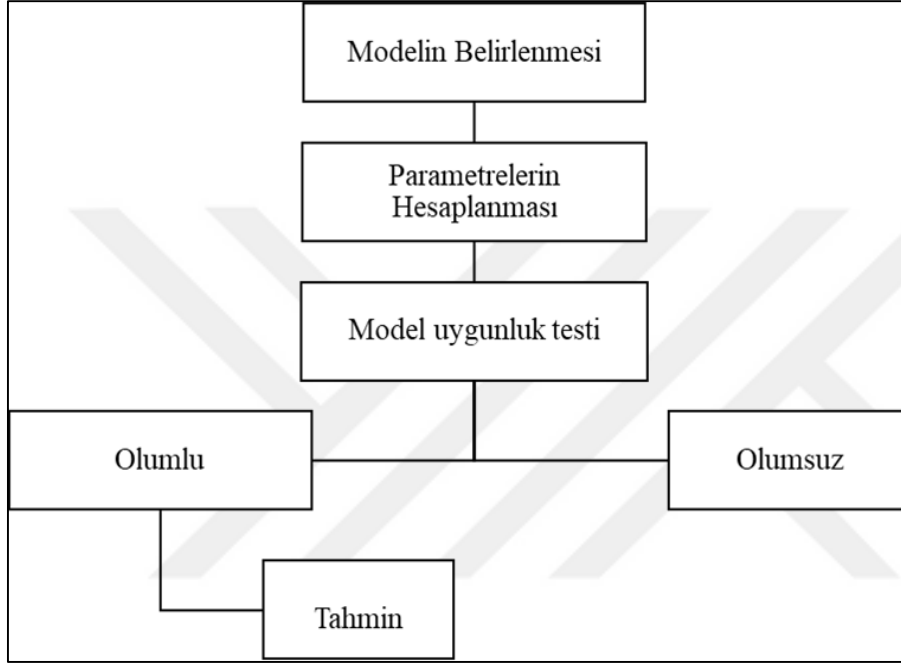
Otoregresif Hareketli (ARMA) Süreç

Hareketli Ortalama (MA) Süreç

Box-Jenkins, hem regresyon modellerinden hem de zaman serileri metotlarını birleştiren tahmin yöntemlerinden biridir. Sonuçta Box Jenkins modelini oluşturmadan önce ARIMA modelinin anlaşılması gerekmektedir (Bal, 2015).

Box-Jenkins modelini oluştururken dört aşamadan geçmesi gerekmektedir. Bu aşamalar aşağıdaki gibidir (Sarı, 2016).

- ✓ **Modelin Belirlenmesi:** Tahmin edilecek zaman aralığı belirlenir.
- ✓ **Modelin parametrelerinin kestirimi:**
- ✓ **Modelin uygunluğunun araştırılması:** İlgili modelin gerekli istatistiksel yöntemler ile anlamlılığı araştırılmalıdır. Eğer anlamlı bulunmuyorsa tekrar başa dönülerek uygun model oluşturulması gerekmektedir.
- ✓ **Tahmin:** Elde edilen modeller içinde en uygun olanı tahmin aşamasında kullanılır.



Şekil 2.3. Box - Jenkins Tahmin Aşamaları

Kaynak: (Kuzu & Yıldırım, 2017)

2.3.2.5.1. Otoregresif Modeller – AR(p) Modelleri

Bu modellerin genel gösterimi AR(p) sekindedir. Burada p değeri geçmiş dönem sayısını verir. Model, geçmiş p dönemdeki zaman serisi değerlerinin ağırlıklı toplamının ve rassal hata değerinin bir fonksiyonudur. AR(p) modelinin genel gösterimi aşağıdaki gibidir.

$$Y_t = \mu + \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + \varepsilon \quad (2.2)$$

Formülde μ değeri serinin ortalamasını verirken, Φ_1, \dots, Φ_p otoregresif parametreleri göstermektedir. ε değişkeni ise serinin hata değişkenini temsil etmektedir.

2.3.2.5.2. Hareketli Ortalamalar – MA(q) Modelleri

MA(q) modelinde Y_t değeri, serinin geriye doğru q dönem geçmiş hata terimlerinin ve ortalamasının doğrusal fonksiyonudur. MA(q) modelinin genel gösterimi aşağıdaki gibidir.

$$Y_t = \varepsilon_t - \Theta_1 \varepsilon_{t-1} - \Theta_2 \varepsilon_{t-2} - \dots - \Theta_q \varepsilon_{t-q} \quad (2.3)$$

Formül üzerinde $\varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-p}$ hata terimlerini, $\Theta_1, \Theta_2, \dots, \Theta_q$ değerleri de hata terimlerinin katsayılarını göstermektedir.

2.3.2.5.3. Otoresif Hareketli Ortalama Yöntemi – ARMA(p,q)

ARMA modelleri en genel durağan stokastik süreç olup, geçmiş gözlemlerin ve geçmiş hata terimlerinin doğrusal bir fonksiyonudur (Önder & Hasgöl, 2009). ARMA (p,q) modelleri genel olarak aşağıdaki gibi gösterilebilir.

$$Y_t = \mu + \Phi_1 Y_{t-1} + \dots + \Phi_p Y_{t-p} + \varepsilon_t - \Theta_1 \varepsilon_{t-1} - \dots - \Theta_q \varepsilon_{t-q} \quad (2.4)$$

Model, zaman serisinin t anındaki tahmininin p adet önceki dönem gözlem değeri ile q adet önceki dönem hata değerinin bileşiminden meydana gelir. Tahmin p sayıda içsel bağımlılık parametresi ($\Phi_1, \Phi_2, \dots, \Phi_p$) ve q sayıda hata parametresi $\Theta_1, \Theta_2, \dots, \Theta_q$ içerir.

2.4. Talep Tahmin Aşamaları

Talep tahmini genel olarak 5 aşamadan oluşmaktadır. Bu aşamalar aşağıdaki gibi tanımlanmıştır (Yazıcıoğlu, 2010).

2.4.1. Talebi Etkileyen Etkenlerin Belirlenmesi

Talep tahmini, yapılmasından önce işletmenin hangi piyasada bulunduğu ve ne gibi ürünleri ürettiği ve ne gibi ürünleri üretmek istediği araştırılmalıdır. Burada gelecek dönemlerde hedefleri, ekonomik gelişmeler ve talebi etkileyen etkenler belirlenmelidir. Bu aşamada tahmini yapılacak olan konu ile ilgili bir çok yönden araştırma yapılarak ilgili konu hakkında detaylı bilgilere ulaşılması ve bu bilgilerin önem sıralaması yapılması gerekmektedir. Çünkü bu aşama tüm tahmin sürecinin temelini oluşturmaktadır.

2.4.1.1. Verilerin Toplanması

Yapılan talep tahmini sonuçlarını etkileyeceği düşünülen etmenlere ait verilerin toplanıp belirli bir düzen içinde toplanmasıdır. Bu aşama tahmin için en önemli aşamalardan birisidir. Kullanılmak istenen veriler geleceğin doğru tahmin edilmesi için geçmişte gerçekleşen değerlerden olması gerekmektedir. Burada tahmin eden kişi amacı doğrultusunda veri toplanması gerektiğini dikkate alarak ilerlemesi gerekmektedir. Eksik toplanan veriler ve

gereksiz yere toplanan veriler zaman ve maliyet kaybına sebep olacaktır. Gereksiz olarak toplanan veriler ulařılan tahmin deęerleri üzerinde de etkili olacaktır.

2.4.1.2. Talep Tahmin Periyodunun Tespiti

Yapılan arařtırmada kullanılan verilerin uzun ve kısalıęına gre deęerlendirilmektedir Yani kısa sreli verileri uzun dnem tahminlerinde kullanırsa hatalı sonular verecektir Bu nedenle kısa sreli tahminler iin kısa sreli veriler kullanılmalıdır. rneęin, eęer aylık bir veri seti tahmini yapılacaksa aylık veriler kullanılmalıdır. Gnlk verileri kullanırsak bizleri yanlış sonulara ynlendirecektir. Bu nedenle tahmin edilen sre ile kullanılan sre birbiri ile doęru orantılı olmak zorundadır.

2.4.1.3. Tahmin Ynteminin Seimi

Tahmin yapılma ařamasında elde edilen verilerin doęru tahmin yntemi ile kullanılması tahmin srecinin en nemli ařamalarında birisidir. Bu nedenle var olan veriler ne kadar anlamlı olursa olsun eęer yntem yanlış seilirse hatalı sonular verecektir. rneęin, nesnel yntemler kullanılıyorsa istatistiksel ya da matematiksel yntemler kullanmalıyız. Eęer znel veriler kullanılıyorsa tecrbeye dayalı yntemler kullanmalıdır. Bunun iin de en iyi yntem olarak anket yntemi rnek olarak verilebilir

2.4.1.4. Tahmin Sonularının Geerlilięinin Arařtırılması

Tahmin sreci iin gerekli ařamaların sonuna gelindięinde elde edilen deęerlerin gerekleřen deęerler ile karřılařtırılarak sonuların analiz edilmesi gerekmektedir. Eęer her iki deęer arasında byk farklar bulunuyorsa geriye ynelik hangi ařamada yanlış bir veri veya yntem kullanıldıęı arařtırılması gerekmektedir.

3. YAPAY SİNİR AĞLARI

İkinci bölümde yapay sinir ağları ile ilgili temel kavramlar ile ilgili bilgiler verilmiştir.

3.1. Yapay Sinir Ağlarının Tanımı

Yapay sinir ağları, insan beyninin deneyimlerinden elde ettikleri bilgi birikimlerini işlemeden yola çıkılarak aynı işlemlerin elektronik ortamda işlenebilir mi sorusunda verilen cevap doğrultusunda yapılan araştırmalar sonucunda oluşturulan bir yöntemdir. Bu yöntem ile tıpkı insan beyninin çalışma prensibi gibi sistem kendisine tanıtılan verileri kendi içerisinde birbirleri ile bağlantılar kurarak araştırılan konu ile ilgili yeni bir sonuç elde edilir (Diler, 2003).

Yapay sinir ağlarının ana kaynağı geçmiş verilerden yararlanılarak gelecekte ortaya çıkması gereken sonuçlar hakkında tahmin yapabilmesidir.

Yapay sinir ağları tıpkı biyolojik sinir sisteminde var olan nöron, dentrit, akson... gibi elemanlardan oluşuyorsa yapay sinir ağlarının da bunlara karşılık gelen işlemci elemanı, toplama fonksiyonu, ağırlıklar gibi.. elemanlardan oluşmaktadır.

Yapay sinir ağı, deneyime dayalı bilgiyi depolamaya ve bu bilgiyi kullanıma sunmaya yönelik doğal bir eğilim içinde olan yoğun paralel dağıtılmış bir işlemcidir” şeklinde tanımlama yapmıştır (Haykin, 1994).

3.2. Yapay Sinir Hücresinin Tarihçesi

Teknolojik gelişmeler ilerledikçe bilgisayarların zaman içinde büyük verileri filtreleyerek özetler şundaki haline gelmesi ve yorumlar yapabilmesi gibi yetkinlikler kazandığı görülmektedir. Şuan da ise bilgisayarlar artık bir çok veriyi özetleyerek bilgiler arasındaki bir çok bağlantı kurabilmektedirler. Bilgisayarların sahip oldukları bu özellikler “yapay zeka” çalışmaları olarak adlandırılır.

Bu süreç ilk olarak 1950’li yılların başında ortaya atılmıştır. Yapay zeka terimi zaman içinde yoğun ilgi görmüş ve 40 – 50 yıl içerisinde ilgi gören araştırmaların temeli haline gelmiştir (Öztemel, 2006).

YSA insan beyninin yapısına ilgi duyulması ile başlamaktadır. Bu çalışmalar aşağıdaki şekilde özetlenebilir.

Gerçek anlamda ilk çalışmalar 1900 yılların başında sinir hücrelerinin varlığının kanıtlanması ile birlikte başlamıştır. 1950 yıllarına gelindiğinde teknolojinin gelişmesiyle birlikte bilgisayar sistemlerinin gelişmesi ile birlikte sinir hücrelerinin matematiksel yöntemler ile hesaplanabileceği ortaya atılmıştır. Bunu en iyi açıklayan teori ise Walter ve McCulloch beraber oluşturdukları sinir hücrelerine ait mantıksal hesap teorisidir. İlerleyen süreçte bu teoriye ek olarak öğrenme algoritmaları geliştirilmiştir. İlk zamanlarda tek katmanlı problemlerin çözümü için kullanılırken bir süre sonra bunun çözümlenememesi yetersiz kaldığının farkına varılmıştır. Bu nedenle daha karmaşık problemlerin çözümü için çok katmanlı problemlerin çözümü için çalışmalar yapılmaya başlanmıştır. 1980'li yıllara gelindiğinde ise çok katmanlı algılayıcılar geliştirilerek ilerlemiştir (Öztemel, 2006).

3.3. Yapay Sinir Ağları ile ilgili Temel Kavramlar

Bu bölümde yapay sinir ağları ile ilgili temel kavramlardan bahsedilmiştir ve açıklamaları yapılmaktadır.


3.4. Biyolojik Yapay Sinir Hücresi

Yapay sinir ağı modelinin anlaşılabilmesi için öncelikle biyolojik sinir sistemini oluşturan ve nasıl çalıştığına dair bilgilerin olması gerekmektedir.

Yapay sinir ağlarının temelinde insan beyinde olduğu gibi biyolojik sinir sisteminde var olan nöronların birbirleri ile bağlantılı olma esasına dayanmaktadır.

Sinir hücresini oluşturan kısımlar şunlardır: Dentrit, akson ve hücre gövdesidir. Sinir hücresi, dentritlerin bağlantı yolları ile hücre gövdesine taşıma işlemi yapmaktadır. Daha sonrasında bu veriler kendi içerisinde değerlendirilerek aksonlar yardımıyla diğer sinir hücrelerine gönderilir (Kaynak, 2000).

Aşağıdaki Şekil 3.1'de biyolojik Sinir hücresi gösterilmiştir.



Şekil 3.1. Biyolojik Sinir Hücresi

Kaynak: (Sarı, 2016)

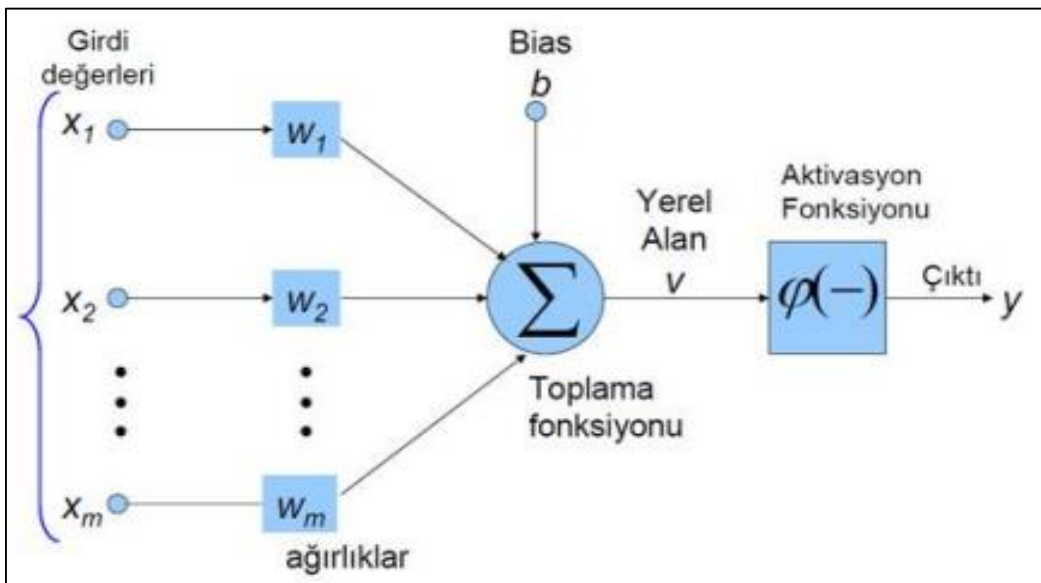
3.5. Yapay Sinir Hücresi

Yapay sinir hücresi biyolojik sinir hücresinin elektronik ortam da oluşturulmasıyla meydana gelen ve temelde çalışma prensibi aynı olan sistemlerdir.

Biyolojik sinir sisteminde olan bulunan bağlantı adları olan Dendrit, akson, snapslar yapay sinir ağlarında işlemci elemanları, fonksiyonlar ve ağırlıklar gibi adlar almaktadır.

Aşağıda Yapay sinir ağlarının temelinde programa girişi yapılan verilerin çeşitli öğrenme yöntemleri ile beraber ve veriler arasında ilişki kurarak araştırmacıya tahmin sonuçları sunmaktadır.

Aşağıda yapay sinir hücresi Şekil 3.2’de gösterilmiştir.



Şekil 3.2. Yapay Sinir Ağın Tasarımı

Kaynak: (Sarı, 2016)

Biyolojik sisteminde adlandırılan terimlerin yapay sinir ağlarında bulunan karşılıkları aşağıdaki gibidir.

Çizelge 3.1. Biyolojik Sinir Hücresi ile YSA Hücresinin Karşılaştırılması

| Biyolojik Sinir Hücresi | Yapay Sinir Hücresi |
|--------------------------------|----------------------------|
| Nöron | İşlemci Elemanı |
| Dentrit | Toplama Fonksiyonu |
| Sinaps | Ağırlıklar |
| Hücre gövdesi | Transfer Fonksiyonu |
| Akson | Çıkış |

3.5.1. Girdiler

Girdiler (x_1, x_2, \dots, x_n) dışarıdan aldığı bilgiyi araçlar sayesinde sinire getirir (Elmas, 2011).

Yapay sinir hücresinin ilk algı katmanı olan girdiler dışarıdan gelen bilgilerden oluşmaktadır. Bu katmanda girdi değerleri hiçbir şekilde işlem görmeden bir sonraki katmana iletilmektedir.

3.5.2. Ağırlıklar

Ağırlıklar (w_1, w_2, \dots, w_i), girişlerin sinir üzerindeki etkisini belirleyen en uygun katsayılarıdır. Her bir girdi verisinin kendine ait bir ağırlığa sahip olması gerekmektedir. Eğer ağırlığın değeri büyük ise o veri yapay sinire güçlü bir ağ ile bağlı olduğunu göstermektedir. Eğer tam tersi olarak ağırlık düşük ise veri yapay sinir ağı ile bağlantısı düşük demektir (Elmas, 2011).

3.5.3. Toplama Fonksiyonu

Toplama fonksiyonlarında problemin yapısına göre bazen gelen girdilerin sayısı dikkate alınırken bazen de gelen girdilerin değerleri dikkate alınmaktadır. Toplama fonksiyonu için belirlenmiş bir kural olmadığından dolayı deneme yanılma yöntemi ile belirlenmektedir.

Net girdi : Ağırlık değerleri ile girdi değerlerinin birbirleri ile çarpımıyla elde edilir. Daha sonra bu değerlerin toplamı ile yeni bir girdi elde edilir.

$$\text{Toplam} = \sum_{j=1}^n [x(i) w_i] \quad (3.1)$$

Net girdi: Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleriyle çarpılarak yeni bir girdi değeri elde edilir.

$$\text{Çarpım} = \prod_i^n x_i w_i \quad (3.2)$$

Net girdi : Tüm girdilerin ağırlık değerleri girdi değerleri ile çarpılmasıyla içlerinden en büyük değer yeni girdi olarak tercih edilir.

$$\text{Maksimum} = \text{Maks} (X_i * W_i) \quad (3.3)$$

Net girdi: Tüm girdilerin ağırlık değerleri girdi değerleri ile çarpılmasıyla içlerinden en küçük değer yeni girdi olarak tercih edilir.

$$\text{Minimum Net} = \text{Min} (X_i * W_i) \quad (3.4)$$

Net girdi: Tüm girdilerin ağırlık değerleri girdi değerleri ile çarpılmasıyla elde edilip burada pozitif ve negatif değerler arasında en büyük sayı değeri yeni girdi değeri olarak kabul edilir.

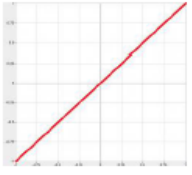
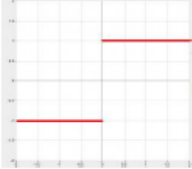
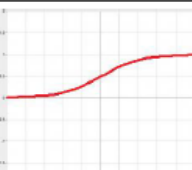
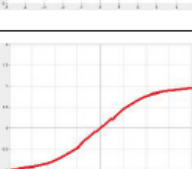
$$\text{Çoğunluk} = \sum_i^n \llbracket \text{Sgn } x_{-}(i) \rrbracket w_i \quad (3.5)$$

Hücreye gelen tüm bilgiler toplanır ve bu şekilde net girdisi hesaplanır.

$$\text{Kümülatif} = \text{Net}(\text{Eski}) \sum_i^n x_{-}(i) w_i \quad (3.6)$$

3.5.4. Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu yukarıda açıklaması yapılan net gir tanımlarında birisi seçilerek hücrenin bu veri karşısında üreteceği çıktıyı belirlemesini sağlar. Burada verinin hesaplanabilmesi için bir çok formül kullanılmaktadır. Burada sigmoid fonksiyonu kullanılmaktadır. Bu fonksiyona ait formül aşağıdaki gibi gösterilir.

| | | | |
|--|---|---|--|
| Doğrusal (Lineer) Aktivasyon Fonksiyonu |  | $F(\text{Net})=A \cdot \text{NET}$ (A sabit bir sayı) | Doğrusal problemler çözmek amacıyla aktivasyon fonksiyonu doğrusal bir fonksiyon olarak seçilebilir. Toplama fonksiyonundan çıkan sonuç, belli bir katsayı ile çarpılarak hücrenin çıktısı olarak hesaplanır. |
| Adım (Step) Aktivasyon Fonksiyonu |  | $F(\text{Net})= \begin{cases} 1 & \text{if Net} > \text{Eşik Değer} \\ 0 & \text{if Net} \leq \text{Eşik Değer} \end{cases}$ | Gelen Net girdinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır. |
| Sigmoid Aktivasyon Fonksiyonu |  | $F(\text{Net})= \frac{1}{1+e^{-\text{Net}}}$ | Sigmoid aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayan yapıyla dolayısıyla yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir. |
| Tanjant Hiperbolik Aktivasyon Fonksiyonu |  | $F(\text{Net})= \frac{e^{\text{Net}} + e^{-\text{Net}}}{e^{\text{Net}} - e^{-\text{Net}}}$ | Tanjant hiperbolik fonksiyonu, sigmoid fonksiyonuna benzer bir fonksiyondur. Sigmoid fonksiyonunda çıkış değerleri 0 ile 1 arasında değişirken hiperbolik tanjant fonksiyonunun çıkış değerleri -1 ile 1 arasında değişmektedir. |
| Eşik Değer Fonksiyonu | | $F(\text{Net})= \begin{cases} 0 & \text{if Net} \leq 0 \\ \text{Net} & \text{if } 0 < \text{Net} < 1 \\ 1 & \text{if Net} \geq 1 \end{cases}$ | Gelen bilgilerin 0 dan küçük-eşit olduğunda 0 çıktısı, 1 den büyük-eşit olduğunda 1 çıktısı, 0 ile 1 arasında olduğunda ise yine kendisini veren çıktılar üretilebilir. |
| Sinüs Aktivasyon Fonksiyonu | | $F(\text{Net}) = \text{Sin}(\text{Net})$ | Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır. |

Şekil 3.3. Yapay Sinir Ağlarına ait Aktivasyon Fonksiyonu

Kaynak: (Çayıroğlu, 2019)

3.6. Yapay Sinir Ağlarının Avantajları

Yapay sinir ağları problemleri çözüme ulaştırma yöntemi ile gerçekte çözülmesi çok zaman alacak problemleri ve bazen çözülemeyecek problemler akılcı çözümler sunmaktadır.

İnsanların yapay sinir ağını kullanılarak analiz yapması nedeniyle bir çok avantaja sahip olmaktadır. Bunlar aşağıdaki gibi örneklendirilir.

- ✓ Yapay sinir ağları bir çok tahmin yöntemine göre daha kısa zamanda çözüme ulaştırır.
- ✓ Gerçek hayatta problemlerin büyük bir kısmı doğrusal olmayan problemlerden oluşmaktadır. Yapay sinir ağları doğrusal olmayan problemlerin çözümünde başarısında dolayı bir çok alanda kullanılmaktadır.

- ✓ Yapay sinir ağlarında çözümüne başlanan bir problemin çözüm aşamasında değişen herhangi bir değişken üzerinde hemen yeniden sisteme aktarılıp istenen sonuçlar elde edilebilir.
- ✓ Yapay sinir ağları yönteminde veri içerisinde ulaşılması mümkün olmayan değişkenler içinde sonuç çıkarabilmektedir. Yani eksik veriler ile de çalışabilmektedir.
- ✓ Yapay sinir ağları tıpkı insanlar gibi deneyimleyerek öğrenir daha sonra bu öğrendikleri ile genelleme yaparak sonuç çıkarabilir.

3.7. Yapay Sinir Ağlarının Dezavantajları

Tüm tahmin yöntemlerinde olduğu gibi yapay sinir ağları ile de bazen istenilen sonuçlara ulaşamaz. Bu nedenle yapay sinir ağları modelinin de kendi içerisinde dezavantajları bulunmaktadır. Bu dezavantajlar aşağıdaki gibidir.

- ✓ Yapay sinir ağları moldeli oluşturlurken belli bir kurala uyulmaka zorunda değildir. Sistem kendi içerisinde problemin çözümünde en uygun yöntemi bulmaya çalışmaktadır. Fakat bu işlemi deneme yanılma yöntemi ile tekrarladığından her zaman doğru sonuçlara ulaşmayabilir. Bu da modelin sonuçlarına olan güveni azaltmaktadır.
- ✓ Yapay sinir ağlarında kullanılacak olan parametrelerin belirlenmesinde bir kural bulunmamaktadır.
- ✓ YSA modeli içerisinde birden çok öğrenme kuralı bulunmaktadır.ve kullanılması gereken öğrenme algoritmasını yanlış belirlediğinde istenilen sonucu veremeyecektir.

3.8. Mimari Yapılarına Göre Yapay Sinir Ağları

Mimari yapılarına göre yapay sinir ağları iki gruba ayrılmaktadır. Burada iki farklı grupta incelenmesinin sebebi model çözülmeye çalışırken izledikleri yolun farklı olmasından kaynaklanmaktadır. Bu nedenle her iki yapıda da sonuçlar birbirlerinden farklı olmaktadır.


3.8.1. İleri Beslemeli Ağları

Yapay sinir ağlarının ileri beslemeli modelinde hücreler katman halinde bulunmalıdır. İlk katman ürettiği çıkış değer bir sonraki katmanın giriş değeri olarak ilerlemektedir. Burada hiçbir veri bir döngü oluşturmamaktadır (Üreten S. , 2005).

İleri beslemeli ağlarda nöronlar girişten çıkışlara doğru hareket etmektedir. Bir katmanda bulunan nöron sadece kendisinden sonra gelen katman ile ilişkide olabilmektedir. Bu arada

gelen ilk bilgi önce giriş katmanına sonra ara katman ya da katmanlara daha sonra da çıkış katmanına iletilmektedir.

Yapay sinir ağları katman sayılarına göre çok katmanlı ya da tek katmanlı olabilmektedir. İleri beslemeli çok katmanlı yapay sinir ağlarına ait ağ şeması Şekil 3.4'te gösterilmiştir.



Şekil 3.4. İleri Beslemeli Çok Katmanlı Yapay Sinir Ağları

Kaynak: Yüksek, 2007: 25

3.8.2. Geri Beslemeli Yapay Siniri Ağları

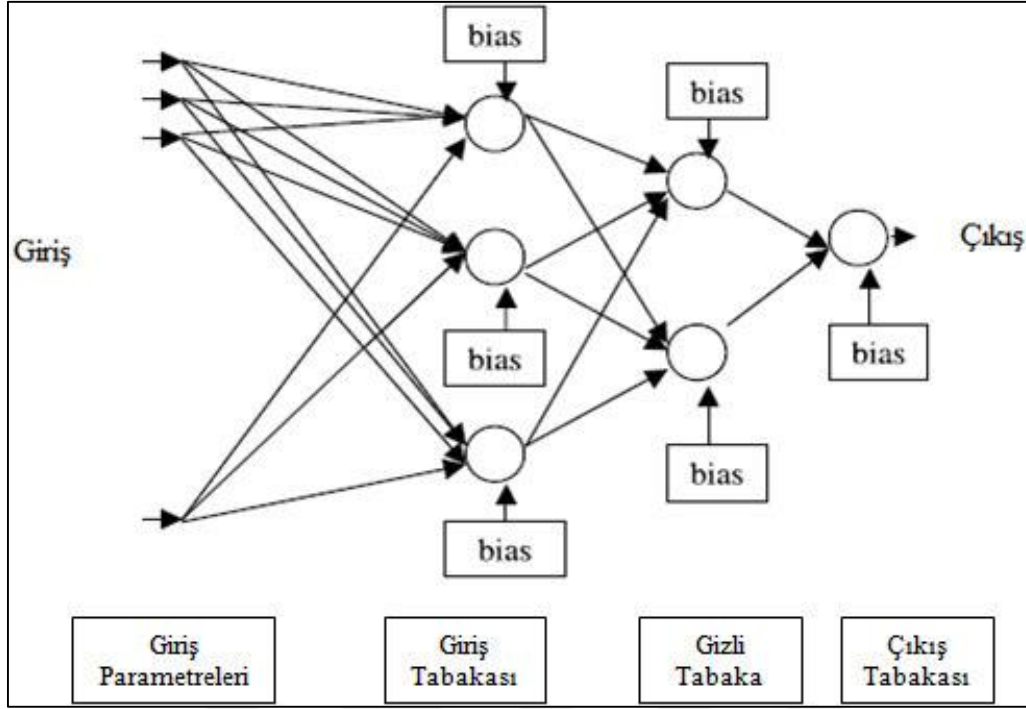
Geri yayımlı ağ modelleri 1970'li yıllardan sonra çözümlenmesi zor olan problemlerin çözümü için geliştirilmiş ve doğrusal olmayan problemlerin çözümünde kullanılmış bir ağ çeşididir.

Araştırmacılar yapay sinir ağları modelinin geri beslemeli modelinde en az bir işlemci elemanının çıktısı, kendisine yada diğer işlemci elemanlara girdi verisi olarak verilmekte ve genellikle geri besleme, bir geciktirme üzerinden yapılmaktadır (Saygılı, 1991).

Geri beslemeli ağlar girdi ,gizli ve çıktı gibi üç katmandan oluşacağı gibi çok katmandan da oluşabilmektedir. Burada çıktı katmanında yer alan bilgi bir önceki katmanlarda girdi olabilmektedir.

Geri beslemeli ağ yapıları her iki yönde de yani giriş ve çıkışlara doğru hareket halinde olduğundan dolayı problem çözümünde süreci karmaşık hale getirmektedir. Geri besleme sayesinde yapay sinir ağlarında öğrenme becerisi artar hem de ağ sonuçları gerçeğe yakın olmaktadır.

Geri beslemeli ağlar birden çok nöron ile ilişkili olduklarında dolayı genellikle çok katmanda oluşmaktadır. Aşağıda Şekil 3.5'te geri beslemeli ağ yapısı gösterilmiştir.



Şekil 3.5. Geri Beslemeli Ağ Modeli

Kaynak: (Sarı, 2016)

Yukarıdaki şekilde anlaşılacağı gibi geri beslemeli ağ modelinde işlemci elemanları karşılaştıkları her hatada öğrendikleri bilgi ile bir sonraki adımda bu hataları dikkate alarak çıktı katmanına doğru ilerlemektedirler.

3.9. Yapay Sinir Ağlarında Öğrenme Algoritmaları

Yapay sinir ağlarının diğer tahmin yöntemlerden ayıran en temel özellik öğrenme yeteneğinin gelişmiş olmasından kaynaklanmaktadır. İlk bölümlerde anlatılmaya çalışıldığı gibi yapay sinir ağları modelinin temelinde insan beninin işleyiş biçimi yer almaktadır. Yapay sinir ağları ile ilgilenen kişilerin odaklandığı nokta ise insanların geçmişte yaşadıkları deneyimlerden elde ettikleri bilgiler ile karşılaştıkları problemlere yaklaşım biçimidir. Problemler karşısında sergiledikleri tutum aslında geçmişte yaşadıkları deneyimlere dayanmaktadır. Yapay sinir ağları da tıpkı insanlar gibi geçmişte yaşadıkları deneyimlerden yola çıkarak ve ilgili konu hakkında bilgi sahibi olarak ilerlemektedir. Yapay sinir ağı modelinin amacı bulunması gereken sonuçlara en yakın sonucu elde etmesidir. Yani aslında hatayı minimize etmektir.

Ağın eğitimi için kullanımına karar verilen eğitim veri setinin öğrenmenin gerçekleşme süreci açısından oldukça önemlidir. Tahmin edilmeye çalışılan modelin tüm yapısını en iyi şekilde açıklayan veri seti ile sonuca ulaşmak istenmektedir (Olgun, 2009).

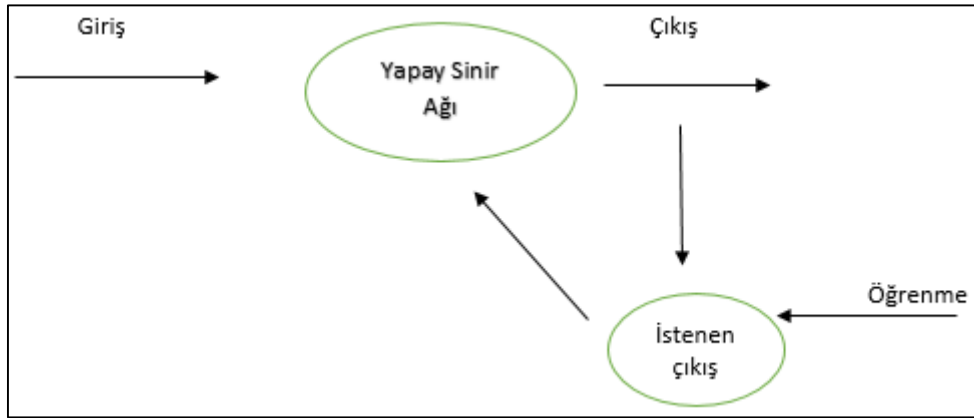
YSA'da ilk öğrenme kuralı Hebb tarafından geliştirilmiştir. Buna göre eğer iki nöron aynı anda çalışırsa aralarındaki bağlantının gücü artmaktadır (Hebb, 1994).

3.9.1. Danışmanlı Öğrenme Yöntemi

Danışmanlı öğrenme yönteminde ağ üzerinde araştırılacak konu hakkında bilgi sahibi olabilmesi adına modelde girdi değerleri ve çıktı değerleri birlikte verilmektedir. Bu sayede kurgulanan ağda daha sonra karşılaşılabilecek benzer verilere karşı nasıl sonuçlar çıkarılması hakkında bilgi sahibi olmaktadır.

Yapay zeka yöntemi kullanılarak yapılan tahminlemenin büyük bir çoğunluğunda danışmanlı öğrenme kullanılmaktadır. Burada kullanılan ağ yapısı gereği gerçekleşen ve istenilen çıkış değerleri karşılaştırılarak ilerlenir. Burada hata değerinin minimum olması istendiğinden dolayı ağ üzerindeki ağırlıklar sürekli değiştirilerek ağın doğru sonuçlar vermesi sağlanır (Olgun, 2009).

Danışmanlı öğrenme yönteminde temel hedef ağın öğrenmesi hedeflendiği için ağa tanıtılan girdi ve çıktı değerleri bir sonraki hedef çıktı değerlerini doğrudan etkilemektedir. Aşağıda Şekil 3.6'da danışmanlı öğrenme yöntemi gösterilmiştir.



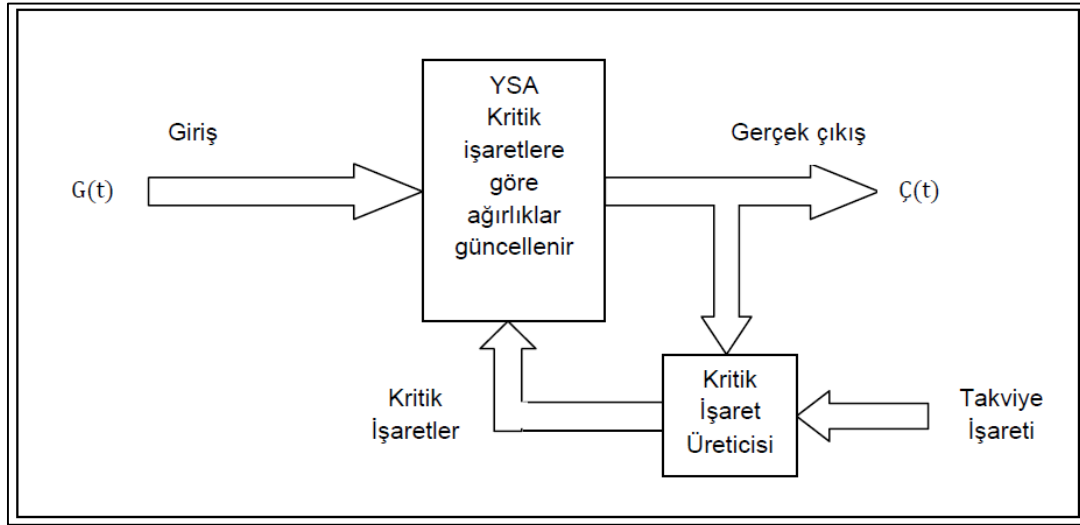
Şekil 3.6. Danışmanlı Öğrenme Algoritması

3.9.2. Danışmansız Öğrenme Yöntemi

Bu öğrenme yöntemine kendi kendine öğrenme yöntemi de denilmektedir. Danışmansız öğrenme yönteminde ağ yapısında sadece giriş değerleri tanıtılarak parametreler arasındaki bağlantıyı kendisi kurması istenmektedir. Burada danışmanlı öğrenme yönteminde olduğu gibi herhangi bir öğrenmeye yardımcı veriler bulunmamaktadır. Danışmansız öğrenmede girdi verileri aynı zamanda çıktı verileri olarak görülmektedir.

3.9.3. Takviyeli Öğrenme Yöntemi

Takviyeli öğrenmede bir nevi danışmanlı öğrenme yöntemine benzemektedir. Takviyeli öğrenme yöntemi ağı her çalıştırılma sonrasında elde edilen değerlerin iyi veya kötü sonuç olup olmadığına dair detayları vermektedir. Yapay sinir ağı elde ettiği bilgiler doğrultusunda kendini yeniden düzenleyerek doğru sonuçlara ulaşmaya çalışmaktadır. Bu sayede sisteme tanıtılan girdiler hem yapıyı öğrenerek hem de gerçeğe yakın sonuçlar çıkararak ağı işlemeye devam etmektedir. Takviyeli öğrenme yapısı Şekil 3.8’de gösterilmiştir.



Şekil 3.7. Takviye Öğrenme Yöntemi

Kaynak: Sarı, 2016: 49

İnsanların yapay sinir ağları, insan beyninin deneyimlerinden elde ettikleri bilgi birikimlerini işlemesinden yola çıkılarak aynı işlemlerin elektronik ortamda işlenebilir mi sorusundan yola çıkılarak yapılan araştırmalar neticesinde elde edilen bir yöntemdir. Bu yöntem ile birlikte tıpkı insan beyninin çalışma prensibi gibi sistem içerisinde birbirleri ile bağlantılar kurarak yeni bir sonuç elde edilir.

3.9.4. Karma Stratejiler Yöntemi

Karma strateji öğrenme yöntemi tüm öğrenme yöntemlerinin birleşiminden oluşmaktadır.

3.10. Yapay Sinir Ağlarında Öğrenme Kuralları

Yapay sinir ağlarında öğrenme kuralları üzerine bir çok yöntem bulunmaktadır. Fakat en sık kullanılan öğrenme kuralları aşağıdaki gibidir.

- ✓ Hebb Kuralı
- ✓ Hopfield Kuralı
- ✓ Kohonen Kuralı
- ✓ Delta Kura

3.10.1. Hebb Kuralı

Hebb Kuralı 1949 yılında Donalt Hebb tarafından geliştirilmiştir. Daha sonra bu kuralı Hebbin bahsedilen yılda yazmış olduğu “The Organization of Behavior “adlı kitabında yer almaktadır. Kural özetle şu şekildedir. Eğer Nöronlar arasındaki ağırlıklar aynı işaretle ise iki bağ arasında güçlü bir bağ bulunmalıdır. Durum tam tersi ise arasındaki bağ değeri zayıf bir bağ olmalıdır (Çelik, 2008).

Hebb kuralı ilk kural olduğundan dolayı tüm kuraların temelini oluşturur. Bu öğrenme kuralına bağlı olarak daha sonraları diğer öğrenme kuralları geliştirilmiştir.

3.10.2. Hopfield Öğrenme Kuralı

Hopfield öğrenme kuralının çıkış noktası Hebb kuralı olduğundan dolayı benzer yönleri bulunmaktadır. Bu kuralda sadece iki nöron arasındaki bağın güçlendirilmesine veya zayıflatılmasına karar verildiğinde bunu gerçekleştirebilmek için bir değer tanımlanması gerekmektedir.

Yapay sinir ağı modelindeki elemanları arasındaki bağlantıların ne derecede kuvvetlendirilmesi veya zayıflatılması gerektiği belirlenir. Beklenen girdi ve çıktıların ikisi de aktif - pasif ise öğrenme katsayısı yardımıyla ağırlık değerleri kuvvetlendirilmeye çalışılır. Aslında ağırlıkların kuvvetlendirilmesi ve zayıflatılması öğrenme kat sayısı ile gerçekleşir. Öğrenme katsayısı kullanıcı tarafından 0 - 1 arasında bulunan pozitif bir değer olmak zorundadır (Yüksek, 2007).

3.10.3. Kohonen Öğrenme Kuralı

1982 yılında Teuvo Kohonen tarafından, ortaya atılmıştır. Bu kurala göre ağ içerisindeki elemanlara ait ağırlıklar iletişim haline geçerek ağırlıklarını değiştirirler. Bu kuralın Hebb kuralından tek farklı tek bir işlemci elemanının ağırlıkları değiştirilmektedir (Saraç, 2004).

3.10.4. Delta Öğrenme Kuralı

Hebb kuralının geliştirilmiş halidir. Widrow ve Hoff tarafından ortaya atılmıştır. Şu anda yaygın olarak kullanılan öğrenme kullarından birisidir. Bu kuralın temelinde gerçek çıktı ile beklenen çıktı arasındaki hata oranının arasındaki farkın azaltılmasına dayanmaktadır.

Delta kuralında da Hebb kuralında olduğu gibi beklenen sonuçlar ve gerçekleşen sonuçlar arasındaki farkı azaltabilmek için ağırlıkların sürekli değiştirilmesiyle oluşturulan bir öğrenme kuralıdır. Burada ağırlıkları sürekli olarak değiştirilmesinin sebebi hata olasılığının azaltılması ve sonuçlara daha bir çıktılar elde edilmek istenmesinden kaynaklanmaktadır.

3.11. Yapay Sinir Ağlarında Çok Katmanlı ve Geri Beslemeli Algoritmalar

ÇKA eğitilmesi genel olarak diğer ağların eğitilmesi ile aynı mantıktadır. Burada diğer ağ modelleri gibi ağın kendisine gösterilen veriler için beklenen değerleri üretmesi istenmektedir. Değerler rastgele atanmaktadır. Amaç en az hata değerine sahip olarak anlamlı bir çıktı üretmek istenmektedir (Öztemel, 2006).

Bu yöntemde oluşturulan ağın performansını en iyi temsil eden şey hata oranının minimum olmasıdır. Öğrenmeye başlayan ağda belirli bir iterasyondan sonra ağın öğrenmesinin sabit kaldığı gözlemlenir (Öztemel, 2006).

3.12. Çok Katmanlı yapay Sinir Ağlarının Çalışma Prosedürü

Çok katmanlı yapay sinir ağlarının çalışma yapısı aşağıdaki gibi sıralanmıştır (Elmas, 2011).

Örneklerin Toplanması: Gerçekleşmiş verilerden oluşması gerekmektedir. Elde edilen veri seti iki ayrı grupta eğitim ve test verisi olarak ayrılır.

Öğrenme parametrelerinin belirlenmesi: Gelecek dönemi tahmin edilmesi için modele geçmiş dönem verilerindeki değişimi öğrenme düzeyini gösteren parametredir.

Ağırlıkların başlangıç değerlerinin atanması: Ağın ağırlık değerleri öncelikle rastgele belirlenir daha sonra uygun değerleri öğrenme sırasında kendi belirler.

Modelin eğitim setinden örneklem seçilmesi: Analizi yapılacak verilerin yüzde kaçının eğitim ve test verisi olarak kullanılması gerektiği belirlenmelidir.

Sonuç değerlerinin karşılaştırılması: Öğrenme sonrasında elde edilen veriler ile gerçek veriler karşılaştırılır burada en önemli kriter hata oranlarının minimum olmasıdır.

Çok katmanlı algoritmalar birçok yapay sinir ağı modelinde kullanılmıştır. ÇKA modelin çözümünde ileri ve geri yayımlı olmak üzere iki farklı yol denenebilir. İleri yayımlı modellerde katmanlar arasında bağlantı bulunmakta beraber danışmanlı olarak eğitilen bir ağ yapısına sahiptirler.



4. UYGULAMA

Perakende sektörü Türkiye'nin hızlı büyüyen sektörlerinden biridir. Ayakkabı sektörü tüm dünyada olduğu gibi ülkemizde de perakende sektörünün öncülerinden biridir. Bu sektör özellikle tekstil sektörü ile yakından ilişkili olduğundan dolayı her dönem birbirleri ile paralel bir ilişki içindedirler.

Talep tahmini uygulaması, yurt içinde ve yurt dışında birçok mağazası bulunan ve ayakkabı, aksesuar, ve ufak bütçeye de sahip olsa tekstil grubunda hizmet veren firmaya ait satış verilerinden yola çıkarak yapılmıştır. Uygulama öncelikle Matlab2013a programında Neural Network algoritmasında eğitim ve test aşamasından sonra bir sonraki yıla ait tahmin çalışması yapılmıştır.

Ayakkabı firmasının geçmiş yıllarına ait satış adetleri kullanılarak gelecek yıl için satış tahmini hazırlanmaktadır. Firma bu tahminleri her yıl bir sonraki yılın resmini daha önceden görebilmek adına tekrarlamaktadır. Yıllık bütçenin dışında dönemlik, aylık, haftalık, kategori bazında, ürün bazında bütçeler hazırlanırken de talep tahminleri yapılmaktadır. Fakat bu tahminler yapılırken mevcut durum göz önüne alınarak yapılır. Gelecek hakkında kesin bilgimiz olmadığından dolayı gerçekleşen ve tahmin değerlerimiz her zaman birbirleri ile uyumlu olmamaktadır. Geçmiş yılların verileri kullanılarak gelecek yılların satış tahmini yapılmaya çalışırken satışı etkileyen diğer faktörlerin belirlenebilmesi için Planlama departman müdürü ve departman yöneticisinin görüşlerine başvurulmuştur.

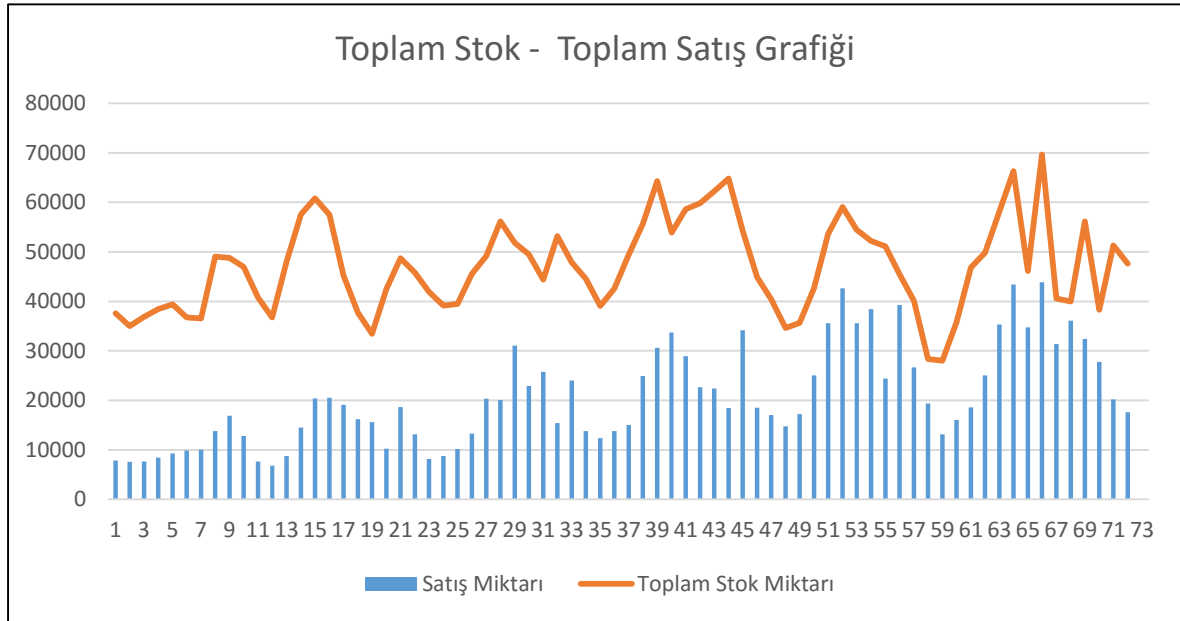
4.1. Amaç ve Kapsamı

Çalışmada, ayakkabı, aksesuar ve tekstil grubunda hizmet veren firmaya ait geçmiş yılların verileri kullanılarak gelecek yılın satış tahmini yapılmıştır. Satış tahmini yapılırken satışları etkileyen dış faktörler dikkate alınarak yapay sinir ağları modeli ile Matlab2013a Programında çözülmüştür.

4.2. Talep Tahmin Probleminin Tanımlanması


Bu çalışmada, ayakkabı sektöründe “Kadın”, “Erkek”, “Çocuk” ve “Spor” grubunda ürün satışını gerçekleştiren firmanın sadece spor ayakkabı grubuna ait satışlarının tahmin edilmesi hedeflenmektedir. Burada yurt içi satışlarını etkileyen dış faktörler aşağıdaki gibi açıklanmıştır.

Toplam Stok Adedi: Mağazalarda bulunan mevcut stok adedi toplam satış adedini doğrudan etkileyen değişkenlerin en önemlilerinden birisidir. Mağazalarda bulunan stok adedi ne kadar çoksa buna paralel olarak satış adetleri de o oranda çok olacaktır. Özellikle ayakkabı sektöründe Erkek Grup en fazla satan numaralar 43 – 44 olurken Kadın Grubunda 37 – 38 numaraların satış adedi her zaman daha fazla olmaktadır. Bu nedenle bu numara aralıklarının mağaza stoklarında hiçbir zaman sıfıra düşmesi istenilmemektedir. Aşağıdaki tabloda aylar içerisinde mağazaların toplam stok adetlerinin değişim grafiği gösterilmiştir.



Şekil 4.1. Toplam Stok – Satış Grafiği

Müşteri Giriş Sayıları: Ciroyu direk etkileyen en önemli değişkenlerden biri de müşteri giriş sayısıdır. Müşteri sayısı arttıkça ciro da buna bağlı olarak artış gösterecektir. Burada önemli olan gelen müşterilerin mağazadan ayrılırken alışveriş yaparak ayrılmasıdır. Aşağıda yıllar arasında müşteri giriş sayılarının değişim grafiği verilmiştir.



Şekil 4.2. Toplam Satış – Müşteri Giriş Sayısı Karşılaştırılması


SKU (Model) sayısı: Perakende sektöründe hem satış adedine hem de ciroya katkısı olan bir diğer değişkenimiz ise model çeşitliliğidir. Bir firma satış yaptığı ürünlerin çeşitliliğini optimum seviyede sağlarsa daha fazla müşteriye hitap edeceğinden dolayı ciroya direkt katkısı olacaktır. Burada üzerinde durulması gereken en önemli nokta her ürünün tüm satış noktalarından olmasından ziyade iyi bir planlama ile doğru ürünün doğru yerde konumlandırılmasına dikkat edilmesi gerekir.

SKU satış potansiyelinin altında sipariş geçilirse;

- ✓ Satış kaybı,
- ✓ Karşılanamayan müşteri talepleri sonucunda memnuniyet düşüklüğü,
- ✓ Müşterilerin rakiplere kaptırılması,
- ✓ Mağazada görsel bütünlüğünün bozulması,
- ✓ RPT(replenishment) siparişleri için ekstra iş gücü ve ürün maliyetinin oluşması,

SKU Satış potansiyelinin üzerinde sipariş geçilmesi sonucunda;

- ✓ Yüksek stok devir oranı,
- ✓ Yüksek indirimler ve kar hedeflerinden sapmalar,
- ✓ Yüksek stok nedeniyle kapasite aşımı,
- ✓ Mağaza görsel bütünlüğünün bozulması,




Şekil 4.3. Toplam Satış – SKU Sayısı Karşılaştırılması

Rakip Sayısı: Rakip sayısı firmaların müşterilerine verdiği mal ve hizmetlerin benzerlik göstermesi sonucunda aralarındaki ilişkiye rakip denir. Perakende sektöründe rakipler birbirlerinin özellikle fiyat politikalarını ve ürün politikalarını yakından takip etmek zorundadırlar. Burada dikkat edilmesi gereken stratejiler kısaca aşağıdaki gibidir.


- ✓ Rakiplerin belirlenmesi
- ✓ Rakiplerin ürün ve hizmetleri nelerdir
- ✓ Rakiplerin fiyat politikaları nelerdir
- ✓ Rakiplerin zayıf ve güçlü yönleri nelerdir
- ✓ Rakiplerin kısa ve uzun vadedeki stratejileri nelerdir.

Mevsim Sıcaklık Ortalamaları: Perakende sektöründe mevsim sıcaklıkları dikkate alınması gereken en önemli değişkenlerden biridir. Yurt içinde ve yurt dışında perakende sektöründe hizmet veren birçok firma hava durumu ile araştırmalar yapan bu konu üzerinde uzmanlaşmış kişilerden danışmanlık hizmeti almaktadırlar. Yıllık planlar hazırlanırken önceden tahmin edilen sıcaklık değerleri göz önüne alınarak sevk planlarını bu verilere dikkate alınarak hazırlamaktadırlar. Örneğin mevsim sıcaklıklarının üzerinde olacağı tahmin edilen 2019 yılı için firmaların yaz sezonuna geçişleri bir önceki yıla göre daha erken olacaktır. Mart ve nisan aylarında mağazalardaki yaz \ kış stok oranı bir önceki yıla göre daha fazla olacaktır. Yani müşteriler yazlık ürünleri bu yıl erken mağazalarda görecektir.



Şekil 4.4. Toplam Satış – Mevsim Sıcaklık Değerleri Karşılaştırılması

Ortalama Fiyat: Toplam ciroyu doğrudan etkiyene en önemli değişkenlerden biri de ortalama fiyattır. Burada fiyatlar TL cinsinden tanımlanmıştır. Yapılan çalışmada alınan veriler aylık olarak belirlendiğinden dolayı fiyat denildiğinde ilgili ayın ortalama fiyat değerinden bahsedilmektedir. Ortalama fiyat grafiği aşağıdaki gibidir.



Şekil 4.5. Toplam Satış – Ortalama Fiyat Karşılaştırması

4.3. Yapay Sinir Ağı Mimarisi

Yapay sinir ağı modeli ile yapılan talep tahmininde en çok kullanılan yöntemlerden biri olan çok katmanlı ileri beslemeli geri yayımlı algoritması kullanılmıştır.

Yapılan talep tahmininde işletmenin hizmet verdiği ürün grubundan biri olan spor ayakkabı kategorisine ait satış tahmini çalışması yapılmıştır. Tahmin için İstanbul ilinde bulunan örnek 15 mağaza seçilmiş ve mağazalara ait veriler kullanılmıştır. Tahmin çalışmasında 2013 Ocak – 2018 Aralık ayları arası seçilmiştir. Bu aylar arasında veriler aylık olarak incelenmiş ve toplam 72 adet veri kullanılmıştır. Verilerin % 70' i yani 50 adedi eğitim verisi olarak kullanılırken geri kalan % 30'luk kısmı 22 veri ağı performansını test etmek amacıyla kullanılmıştır.

Daha önceki bölümlerde anlatıldığı gibi YSA modeli girdi katmanı , ara katman ve çıktı katmanından oluşmaktadır. Yapay sinir ağı modelinde kaç adet gizli katman kullanılacağına dair net bir bilgi bulunmamaktadır. Bu katman sayısı deneme yanılma yolu ile bulunmaktadır. Yapay sinir ağı modelinde gizli hücre sayısı “geometrik piramit kuralı” olarak bilinen bir yöntem kullanılmaktadır.

Bu kurala göre;

- ✓ Gizli hücre sayısı girdi hücre sayısının iki katını geçmemeli,
- ✓ Gizli hücre sayısı girdi hücre sayısı ile çıktı hücre sayısının çarpımının karekökünden az olmamalıdır.

Bu kurala göre; modelimizin gizli hücre sayısı öncelikle girdi hücre sayısı = $6 \times 2 < 12$ gizli hücre sayısı geçmemelidir. Bu çalışmada girdi sayısı 6 çıktı sayısı 1 olduğuna göre 2,44 yaklaşık olarak 3 değeri ilk denemeler için kullanılırken girdi sayısının iki katı olan 12 sayısına göre denemeler tekrarlanmıştır. Modelde girdi katmanı 6 hücreden oluşurken çıktı katmanı ise bir hücreden oluşmaktadır.

4.4. Yapay Sinir Ağlarının Matlab Uygulaması

Yapılan bu çalışmada tüm veriler Matlab 2013 programına girilmiştir. Veriler Matlab programı ile çözülmeye önce tüm verileri Microsoft Excelde normalize edilerek [0,1 - 0,9] arasında olacak şekilde düzenlenmiştir. Normalize edilirken aşağıdaki her bir veri için aşağıdaki formül uygulanmıştır.

Normalizasyon Formülü:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Burada;

X' : Normalizasyon Deęeri

X : İlgili Sütun ve Satırda Bulunan Gerçek Deęer

X_{max} : İlgili Sütunda Bulunan En Büyük Deęer

X_{min} : İlgili Sütunda Bulunan En Küçük Deęer

Tüm veriler yukarıdaki yöntem kullanılarak Microsoft Excel programında normalizasyon işlemine tabi tutulmuştur.

Verilerin normalizasyon işlemi tamamlanmasının ardından kullanılacak olan Matlab programında tahmin edilmeye çalışılmıştır. 2013 – 2018 yılları arasında toplam 50 veri ađın eğitimi için 22 adet veride test aşamasında kullanılmıştır. Modelde 6 adet girdi 1 adet çıktı kullanılmakla beraber tek ara katman kullanılmıştır.

Normalize edilen veriler eğitilmeden önce modelde kullanılması gereken parametrelerin belirlenmesi gerekmektedir. Bu parametreler şu şekildedir. Öğrenme katsayısı momentum katsayısı ve İterasyon sayısıdır. Alan yazında bu parametreler içine belirlenen optimal aralık deęerleri bulunmaktadır. Tahmini yapılan her model için tüm parametreler belirlenen aralık deęerleri arasında deneme yanılma yöntemi ile ađın eğitimi yapılmaktadır. Modeli en iyi açıklayan parametreler ile test verisinin tahmini yapılmaktadır.

4.5. Model Parametrelerinin Belirlenmesi

✓ Momentum Katsayısının Belirlenmesi

Yapay sinir ađlarının eğitilmesinde en önemli kriterlerden biri de momentum katsayısıdır. Momentum katsayısı bir önceki iterasyondaki deęişimin belirli bir oranının yeni deęişim miktarına eklenmesidir. Literatürde en uygun momentum sayısının [0,6 ile 0,9] arasında bir deęer olması gerektięi belirtilmiştir. Fakat problemin yapısına göre her modelde bu deęer deęişmektedir. Bu çalışma için en iyi momentum deęeri belirleyebilmek için deneme yapılarak 2013 yılının Ocak ayı gerçekleşen deęeri = 7850 için momentum katsayısı belirlenmeye çalışılmıştır. Bu deęerin belirlenebilmesi için öğrenme katsayısı: 0,7; İterasyon sayısı:1000 gizli hücre sayısı 3 olmak üzere denemeler yapılmıştır. Aşağıda tabloda görüleceęi gibi iyi deęeri momentum deęeri : 0,7 olarak belirlenmiştir.

Çizelge 4.1. Momentum Katsayısının Belirlenmesi

| Deneme Sayısı | Momentum katsayısı | Normalleştirilen Değer | Tahmin Değeri |
|---------------|--------------------|------------------------|---------------|
| 1 | 0,1 | 0,047 | 8523 |
| 2 | 0,2 | 0,007 | 7040 |
| 3 | 0,3 | 0,100 | 10488 |
| 4 | 0,4 | 0,126 | 11453 |
| 5 | 0,5 | 0,123 | 11341 |
| 6 | 0,6 | 0,212 | 14641 |
| 7 | 0,7 | 0,009 | 7110 |
| 8 | 0,8 | 0,237 | 15568 |
| 9 | 0,9 | 0,038 | 8190 |

✓ *Öğrenme Katsayısının Belirlenmesi*

Yapay sinir ağlarında bir diğer önemli kriter öğrenme katsayısıdır. Öğrenme katsayısının belirlenmesi ağın eğitimini tamamlaması için en önemli değişkenlerden birisidir. Öğrenme katsayısı modelde bulunan ağırlıkların değişim miktarını belirtmektedir. Literatürdeki bir çok çalışma araştırıldığında bu değer 0,2 ile 0,4 arasında değerlerin öğrenme başarısının yüksek olduğu görülmektedir. Fakat bu durum da momentum katsayısı gibi modelin yapısına göre değişkenlik göstermektedir. Bu çalışmada en uygun öğrenme katsayısı 0,7 olarak bulunmuştur.

Çizelge 4.2. Öğrenme Katsayısının Belirlenmesi

| Deneme Sayısı | Öğrenme kat sayısı | Normalleştirilen Değer | Tahmin Değeri |
|---------------|--------------------|------------------------|---------------|
| 1 | 0,1 | 0,273 | 15180 |
| 2 | 0,2 | 0,219 | 13520 |
| 3 | 0,3 | 0,050 | 8320 |
| 4 | 0,4 | 0,043 | 8100 |
| 5 | 0,5 | 0,142 | 11150 |
| 6 | 0,6 | 0,123 | 10570 |
| 7 | 0,7 | 0,037 | 7920 |
| 8 | 0,8 | 0,202 | 13000 |
| 9 | 0,9 | 0,930 | 35410 |

✓ *Nöron Sayısının Belirlenmesi*

Yapay sinir ağ modelinin diğer parametrelerinden biri de katmanlardaki nöron sayısının belirlenmesidir. Nöron sayısının az ya da fazla olması model tahmin değerlerini etkilemektedir. Nöron sayısının fazla olması ağın modeli ezberlemesine ve modelden istenilen performans alınamamasına sebep olmaktadır. Aşağıdaki tabloda momentum sayısı: 0,7; Öğrenme katsayısı: 0,7 alınarak nöron sayısı belirlenmeye çalışılmıştır.

Çizelge 4.3. Nöron Sayısının Belirlenmesi

| Öğrenme katsayısı | Momentum katsayısı | Nöron Sayısı | Normalleştirilen Değer | MSE mean squared error | Tahmin Değeri |
|-------------------|--------------------|--------------|------------------------|------------------------|---------------|
| 0,7 | 0,7 | 1 | 0,144 | -0,115 | 12120 |
| 0,7 | 0,7 | 2 | 0,023 | 0,005 | 7630 |
| 0,7 | 0,7 | 3 | 0,178 | -0,148 | 13380 |
| 0,7 | 0,7 | 4 | 0,064 | -0,035 | 9150 |
| 0,7 | 0,7 | 5 | 0,084 | -0,055 | 9890 |
| 0,7 | 0,7 | 6 | 0,091 | -0,062 | 10150 |
| 0,7 | 0,7 | 7 | 0,072 | -0,043 | 9450 |
| 0,7 | 0,7 | 8 | 0,041 | -0,011 | 8300 |
| 0,7 | 0,7 | 9 | 0,116 | -0,087 | 11080 |
| 0,7 | 0,7 | 10 | 0,063 | -0,034 | 9120 |
| 0,7 | 0,7 | 11 | 0,115 | -0,086 | 11040 |
| 0,7 | 0,7 | 12 | 0,106 | -0,077 | 10710 |
| 0,7 | 0,7 | 13 | 0,043 | -0,014 | 8370 |
| 0,7 | 0,7 | 14 | 0,032 | -0,003 | 7970 |

Momentum katsayısı, öğrenme katsayısı belirli iterasyonlar tekrarlandıktan sonra çevrim sayısının belirlenmesine çalışılmıştır. gerçekleşen değerler ile çevrim sayısının farklı değerlerine göre tahmin edilen değerler kıyaslanmıştır. Sonuçlara göre en uygun çevrim sayısının 1000 olduğu görülmüştür.

Çizelge 4.4. YSA Parametrelerinin Belirlenmesi

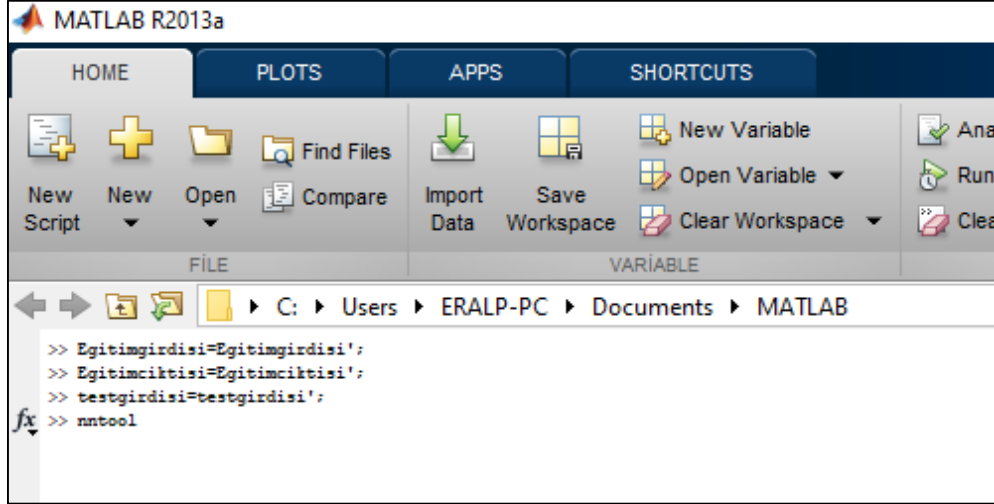
| Öğrenme katsayısı | Momentum katsayısı | Nöron Sayısı | Çevrim Sayısı | Normalleştirilen Değer | MSE | Tahmin Değeri |
|-------------------|--------------------|--------------|---------------|------------------------|--------|---------------|
| 0,7 | 0,7 | 14 | 250 | 0,037 | -0,008 | 5152 |
| 0,7 | 0,7 | 14 | 500 | 0,056 | -0,280 | 6866 |
| 0,7 | 0,7 | 14 | 1000 | 0,081 | -0,052 | 7788 |
| 0,7 | 0,7 | 14 | 2500 | 0,039 | -0,111 | 8238 |
| 0,7 | 0,7 | 14 | 5000 | 0,078 | -0,049 | 9676 |

4.6. Yapay Sinir Ağlarının Eğitilmesi

Modele ait momentum katsayısı, öğrenme katsayısı, gizli hücre katsayısı belirlenmesinin ardından ağın eğitilmesi işlemine geçilmiştir. Ağın eğitilmesi için Matlab 2013a programının Neural Network uygulaması kullanılmıştır. Neural Network uygulamasına yönelik izlenen yöntemler aşağıda sırasıyla belirtilmiştir.

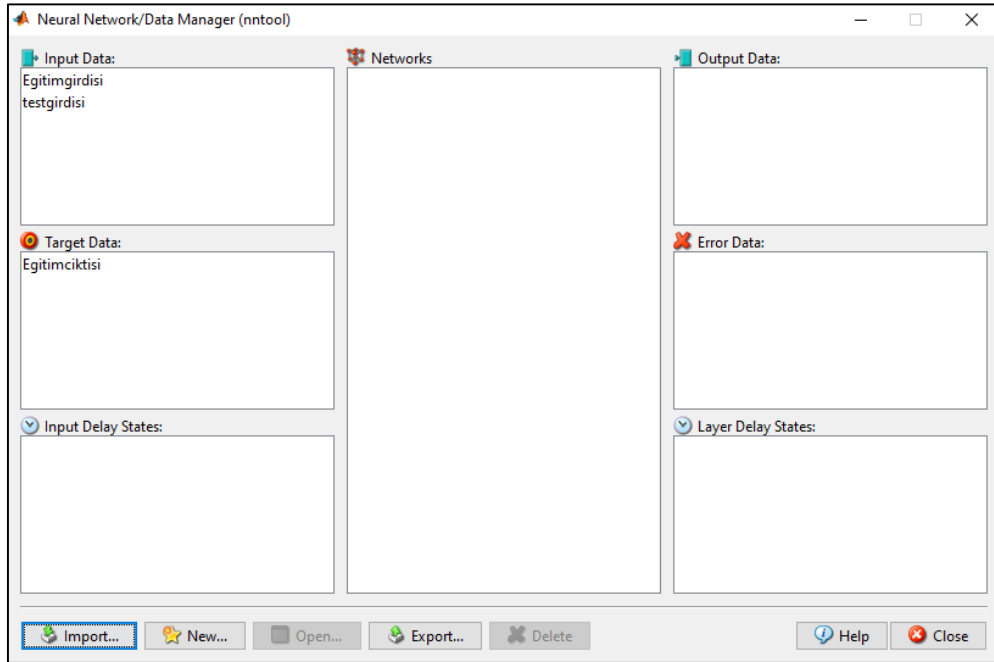
Öncelikle talep tahminin yapacağımız tüm verileri Microsoft Excel'de tek sayfada birleştirmesi gerekmektedir. Toplam 72 verinin ne kadarının eğitim ve ne kadarının test verisi olarak kullanılması kararının verilmesinin ardından test edeceğimiz verisi aynı Microsoft Excel'de farklı bir sayfaya alınarak eğitim verisi ve test verisi şeklinde ayrı ayrı incelenmelidir. Verilerin 50 adedi eğitim girdi verisi ve 22 adedi eğitim test girdi verisi

olarak “Import data” kısmından Matlab 2013a programına normalize edilen değerlerin girişleri yapılır. Matlab 2013a programına tanımlanan değerlerin Transpoze edilmesinin ardından program çalıştırılır. Veriler transpoze edilirken aşağıdaki komutlar programa yazılmalıdır.



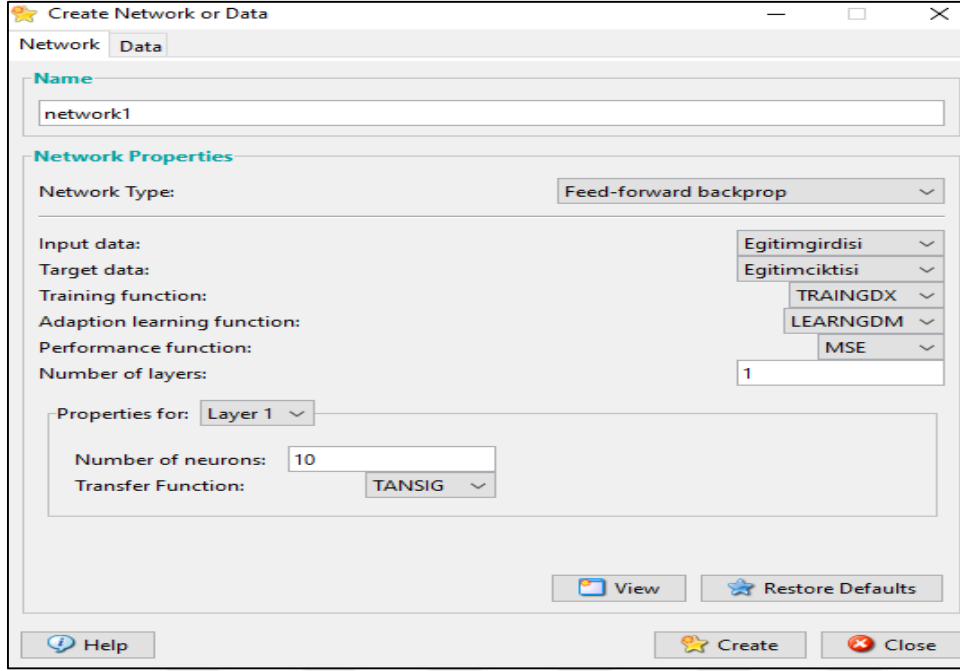
Şekil 4.6. Bağımlı ve Bağımsız Değişkenlerinin Matlab’a Tanıtılması

Programı çalıştırılırken nntool konutu ile karşımıza aşağıdaki ekran çıkmaktadır. Bu ekranda İmput ve Output verimizi gruplamamız gerekmektedir.



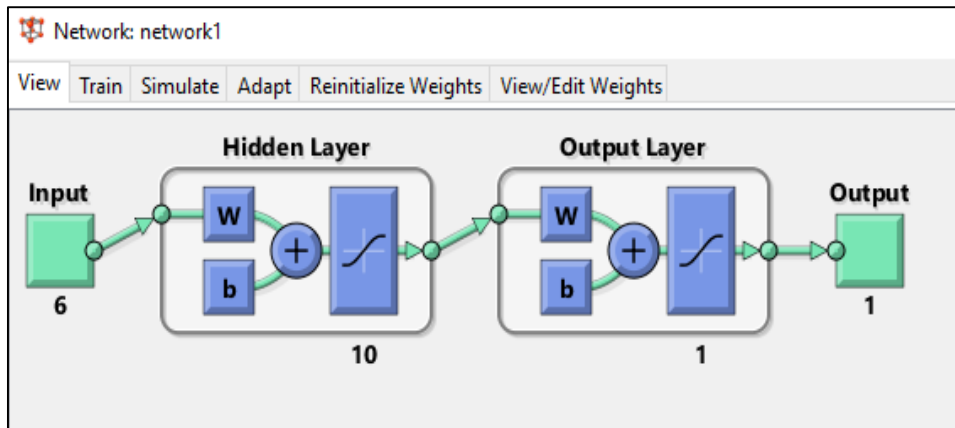
Şekil 4.7. Girdi ve Çıktı Değerlerinin Sınıflandırılması

Verilerin gruplanmasının ardından “New” Sekmesi seçilerek model için gerekli parametrelerin girişleri yapılmalıdır.



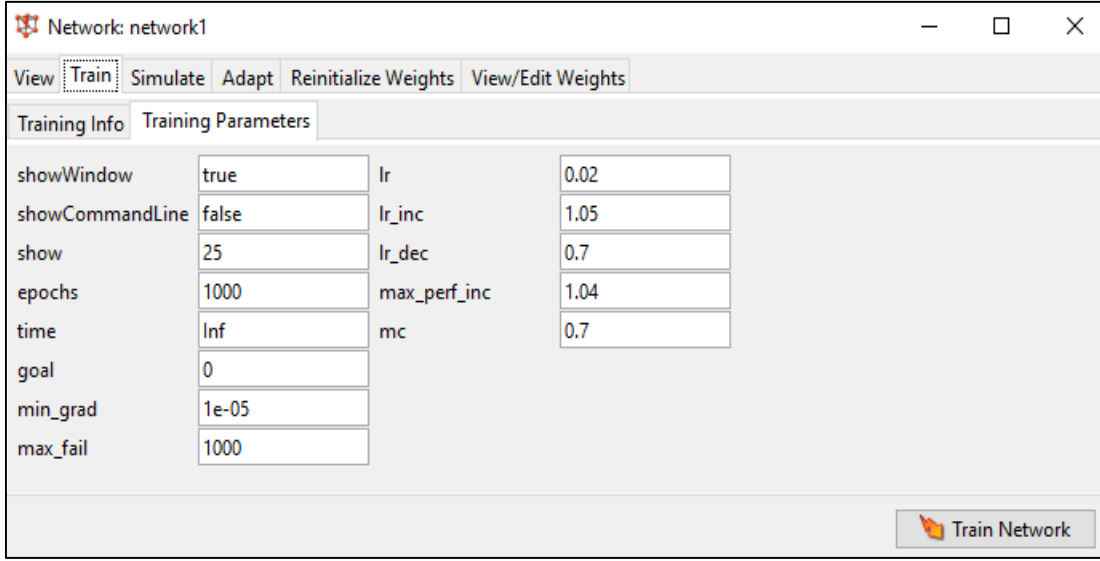
Şekil 4.8. Girdi ve Çıktı Değişkenlerine Ait Parametreler

Yukarıda yapay sinir ağı modelinin ekran görüntüsünde modelde Feed - forward backprop yani ileri beslemeli modelin kullanıldığı eğitim girdi - çıktı verisi, eğitim ve öğrenme algoritmaları, performans fonksiyonu, katman sayısı, gizli hücre sayısı, nöron sayısı ve aktivasyon fonksiyonu girişleri yapıldı sonrasında “Create” butonuna basılarak ağ yaratma işlemi gerçekleştirilir. Oluşturulan ağın ekran görüntüsü aşağıda gösterilmiştir.



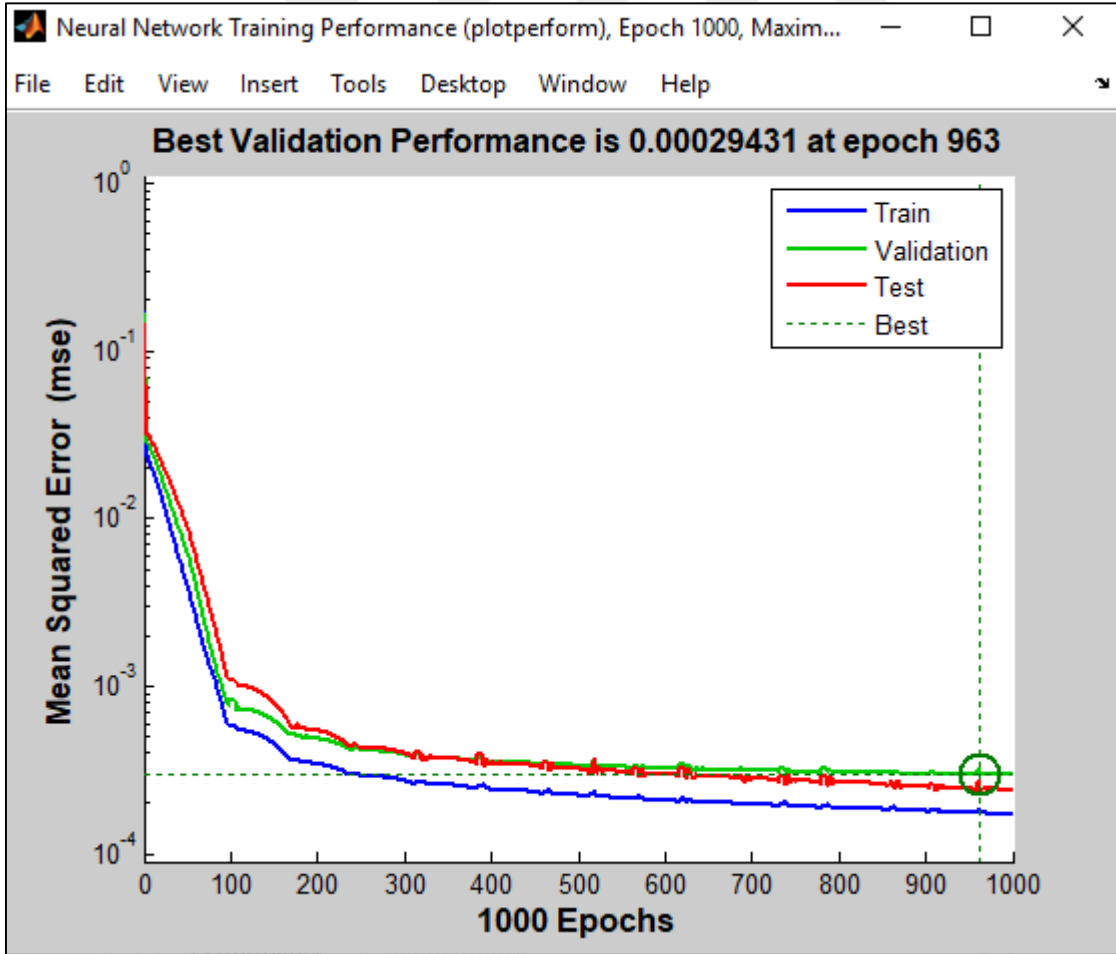
Şekil 4.9. Yapay Sinir Ağı Model Gösterimi

Oluşturulan ağın eğitimi için “Train” sekmesinden ağın eğitim işlemi gerçekleştirilmiştir. Aşağıdaki şekilde Train sekmesine ait ekran görüntüsü bulunmaktadır. Burada ağın eğitimi için gerekli parametreler seçildikten sonra “Train Network” ile modelin eğitimi yapılmaktadır.



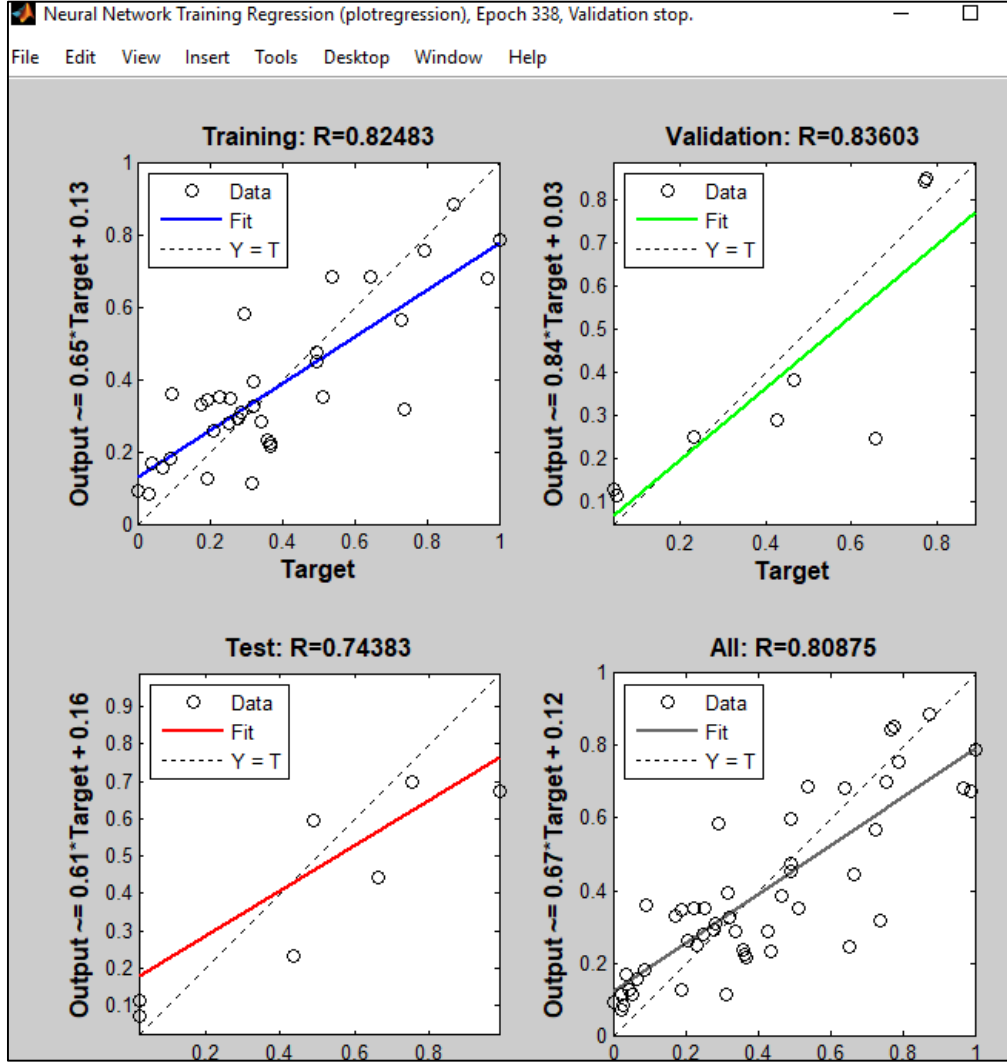
Şekil 4.10. Matlab Yapay Sinir Ağı Eğitim Ekranı

Eğitim sonucunda performans tablosu aşağıda Şekil 4.11’de gösterilmiştir. Eğitim sonucunda model 963 iterasyonda en iyi sonuca ulaşmıştır.



Şekil 4.11. YSA Eğitim Sonrası Performans Grafığı

Öğrenme işleminin ardından Regression sekmesinden eğitilen modelin başarısı aşağıdaki gibidir. Şekil 4.11’den de anlaşılacağı gibi model öğrenme işlemini büyük bir başarı ile gerçekleştirmiştir.



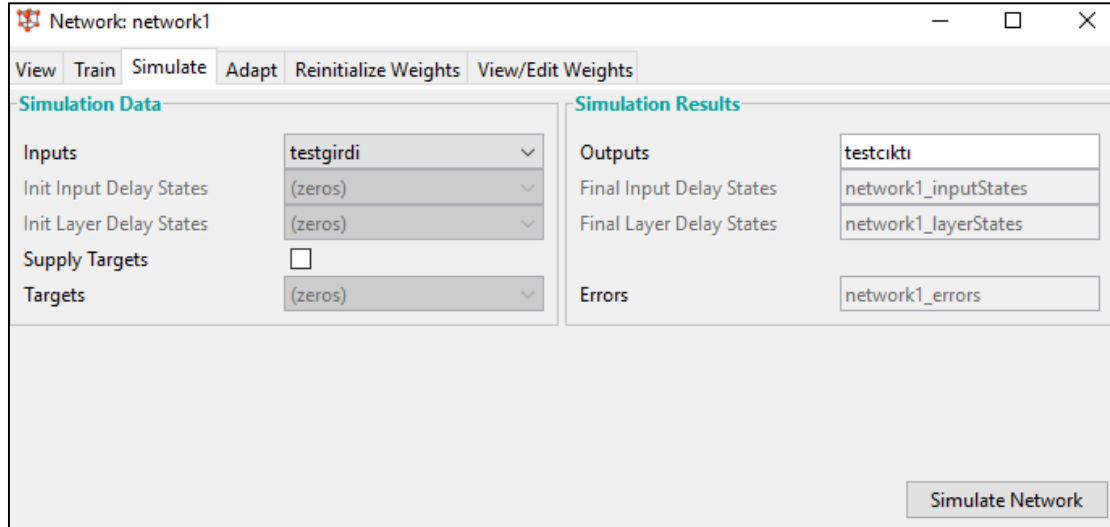
Şekil 4.12. Eğitim Sonrası Öğrenme, Doğrulma, Test Kümelerine İlişkin Regresyon Grafiği

Modelimizi tahmin ederken 72 verinin 50 verisi eğitim girdisi olarak kullanılmaktaydı. Geri kalan 22 adet veri için model tekrar çalıştırılarak test edilmiştir. Eğitim verisinde elde edilen % 82 performansa sahip olan verinin test sonuçları içinde başarılı olması beklenmektedir.

4.7. Sonuçların Test edilmesi

Modelimizi eğittikten sonra test içinde oluşturulan test girdi verileri seçilerek tahmin sonuçlarının üretilmesi istenmektedir. Eğitim yaptığımızı ekran üzerinde “Simulate” sekmesine gelip bu sefer “Inputs” yerine test için ayırdığımız veriyi seçilmesinin ardından çıktı olarak “Workspace” ekranında test çıktısı olarak gelmesini istediğimiz test sonuçları

için Output kısmından adını değiştirmemiz gerekmektedir. Sonrasında “Simulate Network” dediğimizde test verileri için sonuçlar çıkarılmış olacaktır.



Şekil 4.13. Matlab YSA Giriş Ekranı

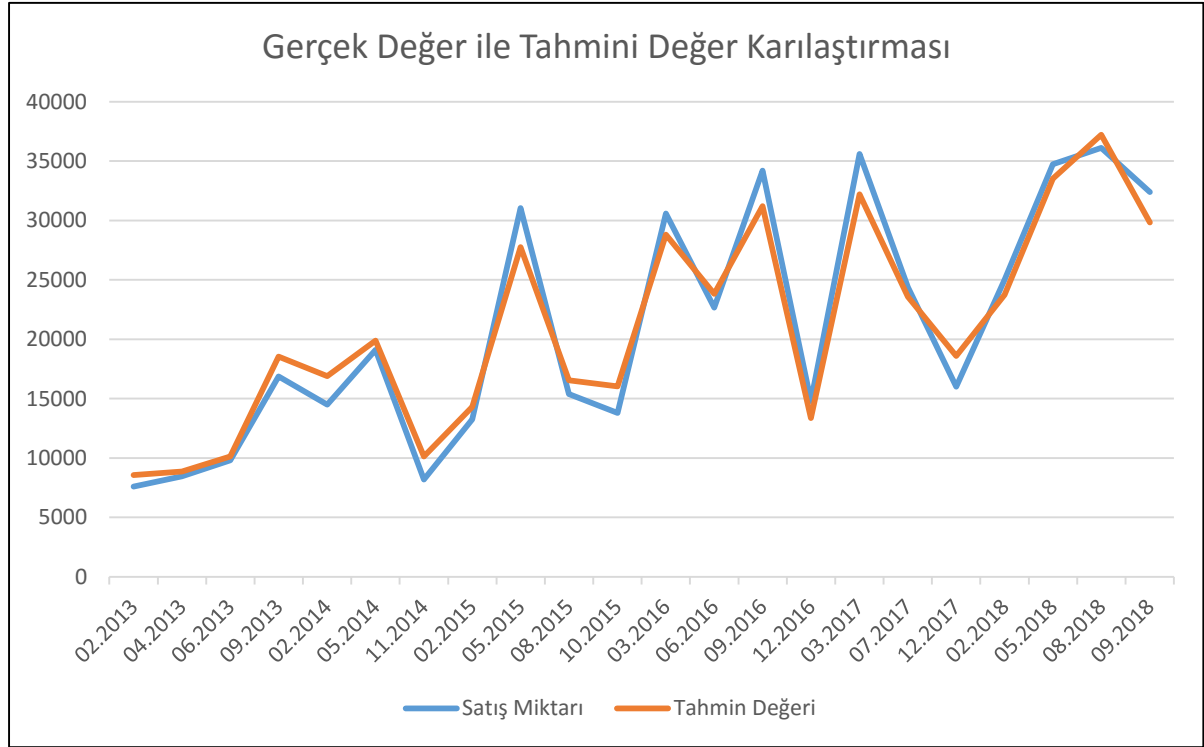
Tahmin işlemi yapıldıktan sonra gerçek veriler ile tahmini yapılan test verileri birbirleri ile karşılaştırılmalıdır.

Çizelge 4.5. Öğrenme Sonrası Tahmin ve Gerçekleşen Değerlerin Karşılaştırılması

| Takvim yılı / ay | Gerçek Değer | Gerçek Değer (Normalize) | Tahmin Değeri | Tahmin değeri (Normalize) |
|------------------|--------------|--------------------------|---------------|---------------------------|
| 02.2013 | 7610 | 0,022384 | 8576 | 0,038438 |
| 04.2013 | 8450 | 0,045038 | 8864 | 0,056204 |
| 06.2013 | 9820 | 0,081985 | 10135 | 0,090472 |
| 09.2013 | 16880 | 0,272384 | 18550 | 0,317429 |
| 02.2014 | 14510 | 0,208468 | 16894 | 0,272768 |
| 05.2014 | 19120 | 0,332794 | 19894 | 0,353668 |
| 11.2014 | 8190 | 0,038026 | 10141 | 0,090645 |
| 02.2015 | 13260 | 0,174757 | 14307 | 0,202995 |
| 05.2015 | 31050 | 0,654531 | 27755 | 0,565679 |
| 08.2015 | 15400 | 0,232470 | 16559 | 0,263734 |
| 10.2015 | 13790 | 0,189051 | 16031 | 0,249494 |
| 03.2016 | 30580 | 0,641855 | 28797 | 0,593757 |
| 06.2016 | 22660 | 0,428263 | 23820 | 0,459559 |
| 09.2016 | 34190 | 0,739213 | 31221 | 0,659138 |
| 12.2016 | 14790 | 0,216019 | 13358 | 0,177391 |
| 03.2017 | 35590 | 0,776969 | 32211 | 0,685839 |
| 07.2017 | 24390 | 0,474919 | 23578 | 0,453014 |
| 12.2017 | 16020 | 0,249191 | 18600 | 0,318761 |
| 02.2018 | 25020 | 0,491909 | 23751 | 0,457678 |
| 05.2018 | 34740 | 0,754045 | 33521 | 0,721182 |
| 08.2018 | 36120 | 0,791262 | 37229 | 0,821164 |
| 09.2018 | 32400 | 0,690939 | 29837 | 0,621826 |

Tabloda tahini yapılan 22 verinin gerçekleşen değerleri ve tahmin değerlerin bir arada verilmiştir. Tahmin değerleri incelendiğinde gerçek değerlere yakın bir tahmin yapıldığı görülmektedir.

Gerçekleşen ve tahmini değerlerin daha iyi anlaşılması için Şekil 3.6'da gösterilmiştir.



Şekil 4.14. YSA İle Bulunan Tahmini Değerler İle Gerçek Değerlerin Grafik Gösterimi

Yukarıdaki şekilde test kümesi için ayrılan 22 verinin gerçek ve tahmini değerlerinin gösterimi yer almaktadır.

4.8. Yapay Sinir Ağları ile Satış Tahmini

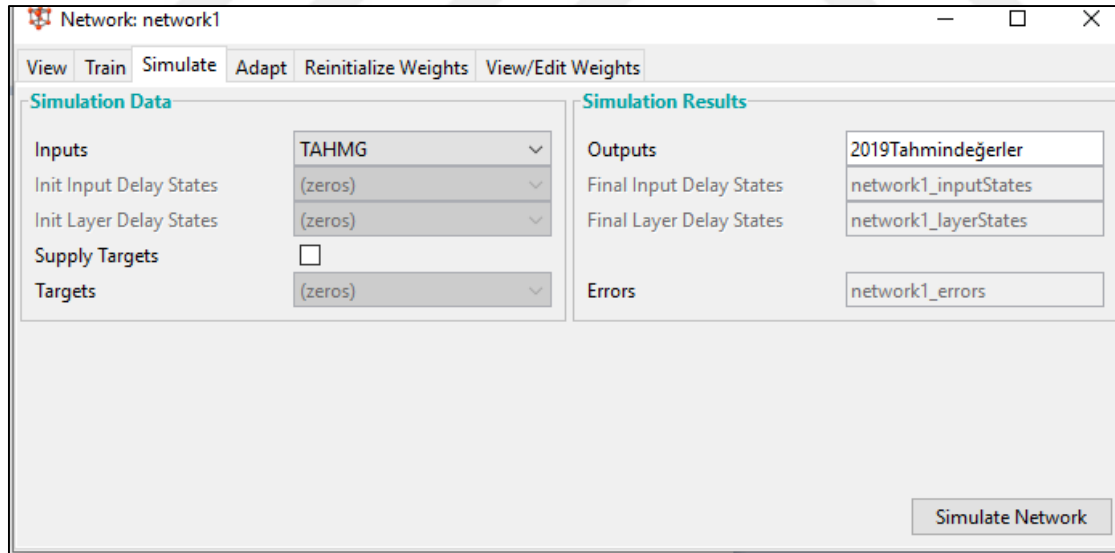
2013 - 2018 yılları arasından belirlediğimiz 50 eğitim verisi ve 22 test verisinin tahmin edilmesinin ardından bu verilerin tahmininde kullanılan parametreler kullanılarak 2019 yılına ait 12 aylık satış tahmini için ağ tekrar simüle edilecektir. Fakat 2019 yılına ait satışların tahmin edilebilmesi için öncelikle bağımsız değişkenlerin belirlenmesi gerekmektedir. Bu değişkenlerden ortalama fiyat, SKU (Model) adedi planlama departmanı tarafından 2018 yılında tahmini yapılan mağazalar için belirlenen SKU adedi talep edilmiştir. Aynı şekilde ortalama fiyatta bir yıl önce planlanan verilerden alınmıştır. Mağaza stok miktarı ise mağazaların kapasitelerinden yola çıkılarak hesaplanmıştır.

Girdi verilerinin 2019 yılına ait 12 aylağa ilişkin tahmin değerleri Çizelge 4.7’de gösterilmiştir.

Çizelge 4.6. 2019 Yılına Ait Girdi Verileri

| Takvim yılı / ay | Stok Miktarı | Ortalama fiyat | SKU Sayısı | Müşteri Sayısı | Mevsim sıcaklık | Rakip sayısı |
|------------------|--------------|----------------|------------|----------------|-----------------|--------------|
| 01.2019 | 98.322 | 100 | 448 | 140737 | 4 | 4 |
| 02.2019 | 104.538 | 99 | 463 | 112636 | 3 | 4 |
| 03.2019 | 122.157 | 108 | 565 | 174325 | 4 | 4 |
| 04.2019 | 90.993 | 113 | 471 | 180044 | 16 | 4 |
| 05.2019 | 96.831 | 104 | 439 | 140696 | 16 | 4 |
| 06.2019 | 87.549 | 91 | 409 | 180042 | 22 | 4 |
| 07.2019 | 85.176 | 83 | 686 | 140767 | 24 | 4 |
| 08.2019 | 83.937 | 98 | 475 | 151930 | 26 | 4 |
| 09.2019 | 117.873 | 100 | 562 | 134976 | 23 | 4 |
| 10.2019 | 80.430 | 100 | 440 | 103449 | 19 | 4 |
| 11.2019 | 107.793 | 106 | 518 | 138342 | 16 | 4 |
| 12.2019 | 100.044 | 95 | 496 | 133419 | 13 | 4 |

Tahmini yapılan bu değerler için YSA kullanılmadan önce [0 - 1] aralığında normalizasyon işlemi yapılmıştır. Normalize edilen değerlerin tahmini yapılmak üzere Matlab Programında Simulate ekranı yardımıyla değerler tahmin edilmiştir.




Şekil 4.15. YSA İle 2019 Yılına Ait 12 Aylık Veri İçin Tahmin Değerleri Test Aşaması

2019 yılına ait 12 aylık veri için normalize edilen değerlerin tahmin edilmesinin ardından değerler gerçek tahmin değerlerine dönüştürülerek aşağıdaki tablodaki belirtilmiştir.

Çizelge 4.7. 2019 Yılına ait Satış Tahmin Değerleri

| Takvim yılı / ay | Tahmin Değeri | 2019 Yılı Gerçekleşen Değerler |
|------------------|---------------|--------------------------------|
| 01.2019 | 39.875 | 32.456 |
| 02.2019 | 44.190 | 38.856 |
| 03.2019 | 47.346 | 42.985 |
| 04.2019 | 54.639 | 42.698 |
| 05.2019 | 55.160 | 50.647 |
| 06.2019 | 60.247 | 52.965 |
| 07.2019 | 47.457 | 55.647 |
| 08.2019 | 52.839 | - |
| 09.2019 | 61.591 | - |
| 10.2019 | 44.185 | - |
| 11.2019 | 63.634 | - |
| 12.2019 | 54.916 | - |

2013 - 2018 yılları arasında 72 aylık verilere ilişkin stok miktarı, SKU (Model) sayısı, ortalama fiyat, müşteri sayısı, rakip sayısı, mevsim sıcaklık değerleri yapay sinir ağı yöntemi ile eğitilerek 2019 yılına ait 12 aylık tahmin değerleri Şekil 4.15'te gösterilmiştir.



Şekil 4.16. Gerçekleşen Satış ve Tahmini Satış Değerlerinin Karşılaştırması

2019 yılına ait satış tahmin değeri tahmin edilmesiyle gerçekleşmesi gereken satış grafiği yukarıdaki şekilde gösterilmiştir.



5. SONUÇ VE DEĞERLENDİRME

İşletmeler gelecek dönemler hakkında bilgi sahibi olmak isterler ve bu nedenle birçok konuda çeşitli tahmin yöntemlerine başvururlar. Bu tahmin yöntemlerinde biri olan ve son yıllarda geliştirilen yeni yöntemlerden birisi de yapay sinir ağları modelidir. Yapay sinir ağları modeli tıp, lojistik, finans gibi farklı alanlarda hem tahmin yapabilme yeteneği olduğundan dolayı hem de gerçeğe daha yakın sonuç verebilmesinden dolayı birçok araştırmada kullanılmaktadır.

Bu çalışmada ayakkabı sektöründe yurt içinde ve yurt dışındaki mağazaları aracılığıyla hizmet veren bir firmaya ait 2013 - 2018 arasındaki aylık veriler kullanılarak 2019 yılına ait aylık satış rakamları tahmini yapılmamıştır.

Çalışmada ilk olarak çalışmanın girdi verisi olacak olan bağımsız değişkenler belirlenmiştir. Bağımsız değişkenler belirlenirken şirket içinde ilgili departmanın müdürü ile yapılan görüşmeden sonra belirlenmiştir. Bağımsız değişkenler olan toplam stok adet, müşteri sayısı, SKU (model) sayısı, ortalama fiyat, rakip sayısı gibi veriler işletmeden alınıp mevsim sıcaklık değerler Metablue adlı hava durumu paylaşan internet adresinden alınmıştır. Çalışmada 2013 - 2018 yılları arasındaki 72 aylık verinin bağımsız değişkene ait değerler belirlenmesiyle birlikte ağın eğitim ve test aşamasına geçilmiştir. Ağın test ve eğitim aşamasındaki % (yüzde) dağılım şu şekildedir. 72 verinin % 70' i (50 adet veri) eğitim ve % 30'u (22 adet veri) test için kullanılmıştır. Tüm veriler normalize edilerek yani tüm veriler [0 – 1] aralığına çevrilerek ağ önce eğitildi ve eğitim sonucundaki tahmin değerleri gerçek değerler ile karşılaştırıldı. Gerekli parametreler belirlendikten sonra test aşamasına geçilerek ağa tanıtılmayan veriler için sonuç çıkarılması beklendi.

Test aşamasının sonucunda performans değeri yüksek bulunan verilerin eğitim ve test aşaması tamamlamıştır. 2013 - 2018 tarihleri arasında tahmin ettiğimiz model için kullanılan tüm bağımsız değişkenler ve modelin eğitimde kullanılan tüm parametrelerin aynısı 2019 yılının aylık veri tahmininde de kullanılmıştır. 2019 yılına ait gerçekleştireceğimiz tahmine geçmeden önce 2019 yılına ait 12 aylık dönemin bağımsız değişkenlerinin parametrelerine ihtiyacımız bulunmaktadır. Bu nedenle stok miktarı, SKU sayısı, ortalama fiyat ilgili departman tarafından sezon geçiş öncesinde belirlediği hedefler doğrultusunda planlama departmanı tarafından talep edilmiştir. Rakip sayısının ise 1 yıl içinde değişmeyeceği ve mevsim sıcaklık değerleri ise Meteoroloji Genel Müdürlüğüne ait internet adresinden alınmıştır.

Yapılan bu çalışma ayakkabı sektöründe hizmet veren ve sadece İstanbul'da bulunan ve örnek olarak seçilen 15 mazağa için yapılan bir çalışmadır. Çalışmada sadece Spor kategori verileri kullanılarak tahmin çalışması yapılmıştır. Diğer kategoriler tahmin dışında tutulmuştur. Bu çalışmanın işletme için daha genel sonuçlar verebilmesi için tüm mağazaların verileri alınarak ve bu çalışmada bulunmayan farklı bağımsız değişkenler belirlenerek çalışmanın kapsamı genişletilebilir ve bu durumda daha genel bir çalışma yapılmış olacaktır.



KAYNAKLAR

- Acar, Nesime (1994) *Üretim Planlaması Yöntem ve Uygulamaları*, Yeniçağ Yayıncılık, Ankara.
- Aydın, D. (2012). *Yapay Sinir Ağları Yardımı İle Talep Tahmin Analizi ve Deniz Taşımacılığı Sektöründe Bir Uygulama*. Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Bal, B. (2015). *Talep Tahmininde Planlama E- Ticaret Sektörüne Uygulaması*. Yüksek Lisans Tezi, Maltepe Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Bolt J.Gorden (1994) *Market and sales forecasting*, Londra.
- Çağlar, T. (2007). *Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletme de Uygulanması*. Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale.
- Çelik, B. (2008). *YSA Metodolojisi ile Zaman Serisi Analizi: Teori ve Uygulama*. Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Diler, H. A. (2003). İMKB Ulusal - 100 Endeksinin Yönünün Yapay Sinir Ağları hata Geriye Yayıma Yöntemi İle Tahmin Edilmesi. *İMKB İstanbul Menkul Kıymetler Borsası Dergisi*, 66- 69.
- Efendigil, T. (2008). *Müşteri Odaklı Sistemler için Yapay Sinir Ağları ve Bulanık Çıkarım Tabanlı Karar Destek Sistemi Yaklaşımı*. Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Elmas, Ç. (2011). *Yapay Zeka Uygulamaları*. Ankara: Seçkin Yayıncılık.
- Haykin, S. (1994). *Neural Networks: A Comprehensive Foundation*, Prentice Hall PTR Upper Saddle River. USA.
- Hebb, D. (1994). *The Organization of Behavior*. New York.
- Kuzu S. Yıldırım B.F.(2017) *Box-Jenkins ve Gri Tahmin Yöntemleri İle Türkiye’de Hava Yolu Ulaşım Talebinin Tahmini*, Söke İşletme Fakültesi Priene Uluslararası Sosyal Bilimler Dergisi, Aydın
- Meydan, Y. A. (2007). *Talep Tahmin Yöntemleri ve Orta Ölçekli Bir İşletmede Uygulaması*. Yüksek Lisans Tezi, İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Olgun, S. (2009). *Tedarik Zinciri Yönetiminde Talep Tahmini Yöntemler ve Yapay Zeka Tabanlı Bir Talep Tahmini Modelinin Uygulanması*. Yüksek Lisans Tezi, İstanbul Üniversitesi Endüstri Mühendisliği, İstanbul.
- Önder Emrah , Hasgöl Özlem (2009), *Yabancı Ziyaretçi Sayısının Tahmininde Box Jenkins Modei WintersYöntemi ve Yapay Sinir Ağlarıyla Zaman Serisi Analizi*, İşletme Ekonomisi Enstitüsü İşletme Dergisi, İstanbul.
- Öztemel, E. (2006). *Yapay Sinir Ağları*. 2. Baskı. İstanbul: Papatya Yayıncılık.
- Sarı, M. (2016). *Yapay Sinir Ağları ve Otomotiv Firmasında Satış Talep Tahmini Uygulaması* . Yüksek Lisans Tezi. Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- Saygılı, İ. (1991). *Üretim Yönetiminin Fonksiyonları*. İstanbul: Küre Ajans.

- Sertaş, Z. S. (2011). *Türkiye' de Perakende Sektöründe Talebi Etkileyen Etmenler ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması*. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri, Enstitüsü, İstanbul.
- Tekin, M. (1996). *Üretim Yönetimi*. Konya: Arı Ofset Matbaacılık.
- Tokgöz G. Helvacıoğlu Ö. Karaatlı M. Ömürbek N (2012) *Yapay Sinir Ağları ile Otomobil Satış Tahmini*, Uluslar arası Yönetim İktisat ve İşletme Dergisi .
- Türkan Ayşe H. (2007) *Güvenilirlik Analizinde Kullanılan İstatistiksel Dağılım Modelleri*, Çukurova Üniversitesi Fen Bilimleri Enstitüsü, Adana.
- Üreten, S. (2005). *Üretim/İşlemler Yönetimi, Stratejik Kararlar ve Karar Modelleri*. 5. Baskı. Ankara: Gazi Üniversitesi.
- Yazıcıoğlu, N. (2010). *Yapay Zeka İle Talep Tahmini*. Yüksek Lisans Tezi, Uludağ Üniversitesi, Bursa.
- Top, Aykut ve Erdal Yılmaz (2009), *Üretim Yönetimi* (2. Baskı) ,Yaprak Yayınları, İstanbul
- Yüksek, A. G. (2007). *Hava Kirliliği Tahmini YSA Çoklu Regresyon*. Doktora Tezi, Cumhuriyet Üniversitesi Sosyal Bilimler Üniversitesi, Sivas.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : KORKUT, Deniz
Uyruğu : TC
Doğum tarihi ve yeri : 01.06.1988 Sakarya
Medeni hali :
Telefon : 05319685090
e-mail :

Eğitim

| Derece | Eğitim Birimi | Mezuniyet Tarihi |
|--------------|---|------------------|
| Yüksek Lisan | Ankara Hacı Bayram Veli Üniversitesi/ Ekonometri Anabilim Dalı | Devam ediyor |
| Lisans | Gazi Üniveristesi / Ekonometri Bölümü | 2013 |
| Lise | Şht Üst.Tğm. Selçuk Esedoğlu Lisesi | 2009 |

İş Deneyimi

| Yıl | Yer | Görev |
|-------------------|--|-------|
| 2017-devam ediyor | Ziylan Holding\ Mağaza Planlama ve Alokasyon Uzmanı | |
| 2015 | Defacto Perakende A.Ş \ Mağaza Müdürü Avrasya Araştırma Enstitüsü | |

Yabancı Dil

İngilizce

