



## COMPARING ARTIFICIAL NEURAL NETWORKS, REGRESSION, MOVING AVERAGES AND WINTERS EXPONENTIAL SMOOTHING METHODS FOR FORECASTING IN FOOD SECTOR

**Murat Taha BİLİŞİK\***

\* Dr. Öğr. Üyesi, İstanbul Kültür Üniversitesi, İşletme Bölümü, m.bilisik@iku.edu.tr

Received Date:25.11.2020, Revised Date:24.12.2020, Accepted Date:11.01.2021

Copyright © 2021 Murat Taha BİLİŞİK. This is an open access article distributed under the Eurasian Academy of Sciences License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

### ABSTRACT

In this study, a company operating in the food sector was discussed. Sales data of the company operating in the field of walnut importation between 2013-2018 years were included in the study. The purpose of the study is to examine the working problem which is explained and find results and suggestions of the study which have been discussed and to finalize the study. Consequently, with the data set created, demand estimation models which are multiple regression technique; 3, 4, and 6 moving averages techniques; singular, binary and winters' exponential correction methods and artificial neural network method are compared.

**Keywords:** Forecasting, Artificial Neural Networks, Exponential Smoothing, Regression

**JEL-Classification:** C13, C45, C51

## GIDA SEKTÖRÜNDE TALEP TAHMİNİNDE YAPAY SİNİR AĞLARI, REGRESYON, HAREKETLİ ORTALAMALAR VE WİNTERS ÜSTEL DÜZELTME METODLARININ KARŞILAŞTIRILMASI

### ÖZET

Çalışmada, gıda sektöründe faaliyet gösteren bir firma ele alınmıştır. Ceviz ithalatı alanında faaliyet gösteren firmanın 2013-2018 yılları arasındaki satış verileri alınarak araştırmaya dahil edilmiştir. Çalışmanın amacı, veri toplama yöntemi, analiz teknikleri gibi çalışma probleminin incelenebilmesi adına ihtiyaç duyulan gerekli bilgilendirmeleri yapmak; çalışmanın bulguları, sonucu ve önerileri ele alınarak çalışmayı nihayete erdirmektir. Sonuç olarak; oluşturulan veri seti ile çoklu regresyon, 3'lü,



4'lü ve 6'lı hareketli ortalamalar, tekli, ikili ve winters metodu üstel düzeltme yöntemleri ve yapay sinir ağları yöntemi ile talep tahmin modelleri kurulmuş ve karşılaştırılmıştır.

**Anahtar Kelimeler:** Talep Tahmini, Yapay Sinir Ağları, Üstel Düzeltme, Regresyon

**JEL-Sınıflama:** C13, C45, C51

## 1.GİRİŞ

Günümüz modern toplumlarında, bireylerin ve örgütlerin içerisinde bulunduğu sürekli değişen ve gelişen küresel yapı bireyleri ve örgütleri olumlu ya da olumsuz birçok açıdan etkilemektedir. İnsanoğlu var olduğundan beri üretmekte, endüstriyel devrimlere ve gelişmelere maruz kaldığından beri ise ihtiyacından fazla ürettiklerini değerlendirme problemi ile karşı karşıya kalmaktadır. Piyasa koşulları içerisinde şekillenen talep koşulları ve değişimleri ise bu değerlendirme çabasının en temelinde yer almakta ve örgütler adına hayati önem taşımaktadır. Talep kavramının sahip olduğu bu önem, bu kavramın uzun yıllarca ve halen günümüzde de etraflı bir şekilde incelenip araştırılmasına neden olmuştur.

Örgütler, gelecek dönemlerde ortaya çıkabilecek örgütsel problemleri tahmin edebilmek zorundadır. Bununla beraber, kıt kaynaklarla yapılan üretim sınırlı olduğu için, üretim miktarının önceden belirlenmesine ya da tahmin edilebilmesine ihtiyaç duymaktadırlar. Belirli bir süre içerisinde tüketicilerin gelirleri, beğenileri ve satın alabilecekleri diğer ürünlerin fiyatlarının sabit kalacağı kabul edilirse; bir mal ya da hizmetin talep edilen miktarının sadece o ürüne yönelik duyulan ihtiyaca ve ürün fiyatına bağlı olarak değişiklik göstereceğini açıklayan fonksiyonel ilişki talep olarak adlandırılmaktadır. Tüketicilerin, belirli bir fiyat üzerinden satın almaya niyetlendikleri miktar şeklinde tanımlanan talep, olası satış hacmini ifade etmektedir.

Bir mal ya da hizmete olan talebin miktarı ve bu durumun ölçülmesinin gerekliliği yıllar içerisinde talep tahmini kavramının derinlemesine araştırılmasına neden olmuştur. Bu tahmin süreci açısından farklı talep tahminleri kullanılmış, ortaya atılmış, literatüre dahil edilmiş ya da edilmemiştir fakat özellikle son yıllarda giderek daha fazla uygulama alanı bulan ve detaylı araştırılmaya başlanılan "yapay sinir ağları" yöntemi öne çıkmaya başlamıştır. Yapay sinir ağları, nörobiyolojik sistemlerden ilham alan ve nöron olarak adlandırılan işlem birimlerinden oluşan bir yapıdadır. Temel olarak, insan beyninin öğrenme sürecinin sanal ortamda taklit edilmesi çabalarıyla ortaya çıkarılmış bir yöntem olan yapay sinir ağları yöntemi genellikle karmaşık problemlerin çözümünde tercih edilmektedir. Bu çalışmada da, talep kavramı ve daha açık anlaşılabilmesi adına gerekli açıklamalar yapılarak bir uygulama ile talep tahmin yöntemleri karşılaştırılmaya çalışılmıştır.



## 2. Talep Tahmini

Tahmin kavramı, belirli bir değişkenin belli varsayımlar kapsamında gelecek dönemde alabileceği muhtemel değerlerin yaklaşık olarak saptanmaya çalışılması şeklinde tanımlanabilir. Zaman serisi çözümlemesinden de yardım alarak, öngörü, belirlenen değişkenin şu anki ve geçmiş dönemlerdeki gözlem değerlerini de ele alarak varsayımlar vasıtasıyla öngörü değerlerinin sınırlarını belirleyebilme adına gösterilen çabalardır. Başarılı bir öngörünün başarılı kararları getireceği, bunun yanında yararlanılan faydanın maksimum seviyeye çıkartılabileceği gerçeği, öngörü modellemelerine olan ilgiyi yükseltmektedir (Ataseven, 2013: 1).

Tahmin, normal günlük hayatta öngörme, fikir yürütme, kehanet gibi terimlerin aralarındaki farklar dikkate alınmadan çoğu zaman birbirlerinin yerine kullanılması şeklinde karşımıza çıkmaktadır. Benzer durum İngilizce'de de görülmektedir: forecast, predict, estimate ve cast gibi terimler birbirlerinin yerine kullanılabilir (Tokpunar, 2014: 12). Fakat bu kavramlar, her ne kadar günlük yaşantıda birbirlerinin yerine kullanılsa da temelde farklı anlamlar taşımaktadır. Bu çalışma açısından tahmin kavramı talep kavramı ile yakından ilişkili olacağı için her iki kavramın da kısaca açıklanmasına ihtiyaç duyulmaktadır.

Talep kavramı ise, "belirli bir dönemde ve belirli bir pazarda tüketicilerin değişik fiyat düzeylerinde satın almaya istekli oldukları ve satın alabilecekleri ürün miktarı" şeklinde açıklanabilir. Ayrıca, belirli bir süre içerisinde tüketicilerin gelirleri, beğenileri ve satın alabilecekleri diğer ürünlerin fiyatlarının sabit kalacağı kabul edilirse; bir mal ya da hizmetin talep edilen miktarının sadece o ürüne yönelik duyulan ihtiyaca ve ürün fiyatına bağlı olarak değişiklik göstereceğini açıklayan fonksiyonel ilişki talep olarak adlandırılmaktadır. Tüketicilerin, belirli bir fiyat üzerinden satın almaya niyetlendikleri miktar şeklinde tanımlanan talep, olası satış hacmini ifade etmektedir. Bir mal ya da hizmete olan talebin miktarı ve bu durumun ölçülmesi işletmeler adına büyük öneme sahiptir (Aydın, 2017: 2).

Talep tahmini, envanter yönetiminden nakliye, dağıtım, yenileme, üretim, bakım-onarım, tedarikçi koordinasyonuna bir çok iş operasyonunda geniş bir yelpazede kullanılmaktadır (Fildes vd., 2006: 352). Silver, Pyke ve Peterson, tahmini geçmişte gözlemlenen ve gelecekteki olaylara yönelik yargılar doğrultusunda yapılan geleceğe dönük çıkarımların bir kombinasyonu olarak tanımlamaktadır (Silver vd., 2000: 74).

Yöneticiler, gelecek dönemlerde ortaya çıkabilecek örgütsel problemleri tahmin edebilmek zorundadır. Kıt kaynaklar ile yapılan üretim sınırlı olduğu için, üretim miktarının önceden belirlenmesi önemlidir. Yöneticilerin ürünlerine yönelik talebi tahmin edebilmeleri için gelecek dönemlerin genel ekonomik durumunda tahmin edilmesi gerekir. (Öztürk, 2006: 4).



Hem yatırım projelerinin hazırlanmasında hem de ekonomik değişimlerin ve güncel gelişmelerin etkili bir biçimde anlaşılmasında en önemli adımlardan biri de üretilmesi planlanan mal ya da hizmetin günümüzdeki ve gelecekteki talebinin incelenmesidir. Optimum kapasitenin belirlenmesi, karşılaştırma yapılabilmesi, faydaların ortaya çıkarılabilmesi, yatırım projesinin finansal karlılığının sağlıklı bir biçimde değerlendirilebilmesi adına; projen ömrü süresince geçerliliğini koruyacak, gerçeğe en yakın talep tahminini yapmak en önemli koşuldur (Çetinel, 2005: 95).

### 3. Nicel Yöntemler

Nicel yöntemler; geçmiş verileri kullanarak gelecekteki verilerin tahmininin matematiksel olarak yapılmasıdır. Geçmişe yönelik yeterli bilgi bulunuyor ve elde edilen bilgiler matematiksel olarak ölçülebiliyor ise kullanılır. Nicel tahmin yöntemlerinin bir kısmı basit olmasına karşın diğer bölümü karmaşık işlemler içermektedir. Uygulamada bazı yöntemlerin diğer yöntemlere bakıldığında daha uygun sonuçlara olanak sağladığı görülse de, tahmin yöntemleri hakkında bir genelleme yapılarak en iyi yöntem şudur demek doğru değildir. Farklı tahmin yöntemlerinin farklı tahmin yapıları ile birlikte uygulanması ve incelenmesi gerekir (Demirbaş, 2011: 13).

#### 3.1. Ortalamalar Yöntemi

*Basit ortalama yöntemi* geleceğin, geçmişte olanların ortalamasına doğru eğilim göstereceğini varsaymak, talep tahmini açısından en basit yöntemlerden biridir. Bu yöntemde son n dönemde gerçekleşmiş değerler toplanarak ortalaması alınır ve bulunan sonuç tahmini değer kabul edilir. Bu yöntem, gerçekleşen talep değerlerinin trend, konjonktürel ve mevsimsel değişimlerin ve dalgalanmaların etkisinde olmadığı koşullarda; ulaşılabilen az miktarda veriler için başarılı sonuçlar vermektedir. Veri miktarı arttıkça belirli bir trendi yakalayamamaktadır (Demirbaş, 2011: 15-16).

$$F_{t+1} = \frac{1}{t} \sum_{t=1}^t Y_t \quad (1)$$

t = dönem


$F_{t+1}$  = t+1 dönemi için tahmin değeri

$Y_t$  = t dönemindeki gerçekleşen talep değeri

*Ağırlıklı ortalama yöntemi* üstünlüğü yakın dönemin talebine daha fazla önem verilmesine imkan sağlamasıdır. (Aynı mevsimde önceki yıllarda daha yüksek ağırlıklar verilerek mevsimsel etkiler de ele alınabilir.) Tahmin asıl talep serisinin ortalamasındaki değişikliklere, basit ortalama yöntemi tahminine göre daha duyarlı olacaktır (Bal, 2015: 31).

$$F_{t+1} = \alpha Y_t + (1-\alpha)Y_{t-1} \quad (2)$$

t = dönem



$F_{t+1}$  = t+1 dönemi için tahmin değeri

$Y_t$  = t dönemindeki gerçekleşen talep değeri

$\alpha$  = Ağırlık değeri (0 ile 1 arasında olmalı)

### 3.2. Regresyon Analizi Yöntemi

Regresyon analizi yöntemi, bağımlı bir değişkenin bir ya da daha fazla bağımsız ya da açıklayıcı değişken ile arasındaki ilişkinin matematiksel bir fonksiyon biçiminde ifadesidir. Bu fonksiyona regresyon denklemi denilmektedir. Regresyon denklemi yardımı ile, bağımlı değişken ve bağımsız değişkenler arasındaki ilişkiyi oluşturan parametrelerin değerleri tahmin edilmektedir. Bağımlı değişken üzerinde etkisi bulunan bağımsız değişkenlerin tahmin edilebilmesi, bu değişken üzerinde geliştirilebilecek plan ve politikalarda hangi etmenlerin önemli olduğunun tespitinde kullanılmaktadır (Çağlar, 2007: 25).

Yeterli seviyede açıklayıcı güce sahip olan güvenilir bir regresyon katsayısıyla güvenilir tahminler yapılabilmektedir. Regresyon analizinde, eşitlik (formül) dönemselsel olarak değişiklik gösteren geçmiş veriler yardımıyla geliştirilebilir. Tahminde bağımsız değişkenlerin değerleri büyük oranda sıra dışı değerler ise, tahmin hatasının da fazla olması beklenmektedir. Geçmiş verilerin düzenli ve sürekli şekilde oluştuğu durumlarda ise tahminin tutarlılığı da o düzeyde yüksek olacaktır (Karahan, 2011: 44).

Basit doğrusal regresyonda iki değişkenin birbiriyle olan ilişkisinin doğrusal olduğu varsayımına göre tahmin denklemi  $Y=a+bx$  olarak oluşturulur.

### 3.3. Yapay Sinir Ağları

Yapay sinir ağları, parametrik olmayan ve esnek modelleme araçlarıdır (Tang ve Chi, 2005:248). Temel olarak, insan beyninin bilişsel öğrenme sürecinin sanal ortamda taklit edilmesi çabalarıyla ortaya çıkarılmış bir yöntem olarak bilinmektedir ve karmaşık problemlerin çözümünde etkili sonuçlar verdiği görülmüştür. Tahminleme, sınıflandırma, kümeleme gibi çok sayıda probleme çözüm üretmektedir. Sinir ağlarının en fazla ön plana çıkan özelliği karmaşık sistemlerin geçmiş verilerinden fikir edinilerek örnek üzerinde öğrenme tekniği yardımıyla probleme çözüm üretmesidir (Efendigil vd., 2009: 6699; Kuan ve White, 1994: 3).

Yapay sinir ağları, insan beyninin temel seviyelerinin nöronlara benzer hale getirilmesidir ve birbiriyle ilişkilidir. Bir bilgisayarın nasıl bir seçenek oluşturması gerektiğidir. Programda adım adım bir ya da daha fazla yapan iç kurallarını kendisi üretir ve bu kuralları, sonuçları örneklerle karşılaştırarak düzenler (Civalek ve Ülker, 2004:2).




Yapay Sinir Ağları, teknik detaya girilmeksizin en basit ve kısa biçimde, bir örnekler kümesi yardımı ile parametrelerin uyarlanabilmesini sağlayabilecek matematiksel bir formül için yazılan bilgisayar programı şeklinde tanımlanabilir (Anderson ve McNeill, 1992: 4).

Bir sinir ağı, biyolojik beyin paralel hesaplama yeteneğini taklit etmeye çalışan işlem öğelerinin yüksek oranda bağlı bir yapısı olarak düşünülebilir. Biyolojik beyin geleneksel doğrusal bir bilgisayar kadar hızlı hesaplama yapamayabilir. Bununla birlikte, bazı durumlarda biyolojik beyin paralel işlem kabiliyeti verileri anında oluşturabilir, işleyebilir ve genelleştirebilir, buna karşın geleneksel bir bilgisayar çok fazla zaman alacaktır ve çoğu durumda sorunu anlayamayacaktır. Beyni taklit etmeye çalışarak, yapay sinir ağları geleneksel bilgisayarların dezavantajlarının üstesinden gelmeye çalışır (Detienne vd., 2003: 2). Yapay sinir ağları, paralel şekilde bağlantılı basit elemanlardan oluşmaktadır. Bu elemanlar biyolojik sinir sistemine benzer bir yapıya sahiptir. Ağın temel fonksiyonunu bahsedilen elemanlar arasında oluşan büyük çaplı bağlantılar oluşturmaktadır. Elemanların birbirleri ile bağlandıkları ağırlık değerlerinin ayarlanarak belirli bir fonksiyonun gerçekleştirilebilmesi adına ağın eğitimi sağlanmaktadır. Bu şekilde belirli bir girdiye karşılık ağ bir çıktı üretmektedir (Karaatlı vd., 2012: 91).

Sinir ağları potansiyel olarak çok sayıda temel işlem biriminden oluşur; Her birim diğer birimlerle birbirine bağlıdır ve her biri nispeten basit hesaplamalar gerçekleştirebilmektedir. Ağın işlem sonucu, tek bir birimin özel davranışından ziyade kolektif davranışlarından kaynaklanır (Altman, 1993: 9). Yapay sinir ağları nörobiyolojik sistemlerden ilham alır. En eski nöro-bilgisayarlardan birinin mucidi olan Robert Hecht-Nielsen, nöral bir ağı, dış girdilere dinamik durum tepkileriyle bilgileri işleyen bir dizi basit, birbiriyle bağlantılı işleme elemanından oluşan bir hesaplama sistemi olarak tanımlar (Coats ve Fant, 1993: 3).

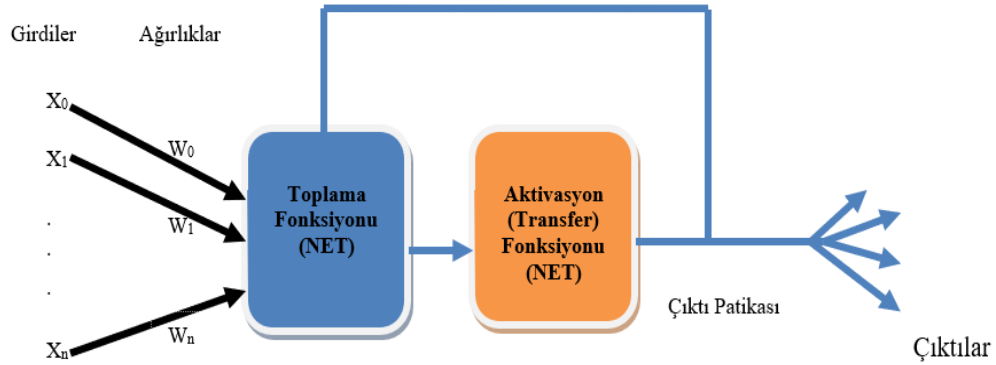
Yapay sinir ağları nöron olarak adlandırılan işlem birimlerinden oluşmaktadırlar. Nöronlar ise genel itibarıyla katman adı verilen mantıksal gruplar içerisinde yer alır. Ağ, 3 ya da daha fazla katmana sahip hiyerarşik bir yapıdadır. Bu ağ içerisinde; 1 girdi, 1 ya da daha çok gizli ve 1 çıktı katmanları bulunmaktadır. Girdi katmanında, ağa girdi desenlerini sağlayan girdi kümesi bulunmaktadır. Girdi katmanı ile sinyalin sağlandığı çıktı katmanı arasında en az 1 gizli ara katman yer almaktadır (Kutlu ve Badur, 2009: 4-5). Yapay sinir ağlarının temel yapısı ve sinir hücrelerinin miktarı değişkenlik gösterse de, yapay sinir ağlarının oluşumu açısından kabul gören bir genel kural bulunmamaktadır. Gereken gizli katman miktarından daha az sayıda gizli katman içeren yapay sinir ağları karmaşık fonksiyonların çözülmesinde yetersiz kalmakta iken, fazla sayıda gizli katman içeren yapay sinir ağları ise istenilmeyen kararsızlıklar ile karşı karşıya kalınmasına neden olabilmektedir. Gizli katman miktarının belirlenmesinin ardından karşılaşılan bir diğer temel problemse her tabakada ne kadar nöronun bulunacağına karar verilmesi problemidir. Girdi katmanı açısından herhangi bir sorun yoktur çünkü



belirlenen girdi sayısı miktarı sistem içerisinde yer alan girdilerin sayısıdır. Benzer şekilde, çıktı katmanında da istenen çıktı miktarıyla belirlenmektedir. Asıl problem, gizli katmanlar içerisinde yer alan nöron sayısını belirleyebilmektir. Geleneksel matris algoritmasında, matris boyutlarının girdi veya çıktı sayısına denk olması gerektiği söylenmektedir. Fakat, gizli katman içerisinde en verimli haliyle ne kadar nöronun yer alacağı noktasında uygulanabilir bir matematiksel test bulunmamaktadır. Nöron sayısına, deneme yanılma yöntemiyle karar verilebilir (Ataseven, 2013: 3).

### 3.3.1 Yapay Sinir Hücreleri


Bir yapay sinir ağı; nöron, birim, hücre, düğüm, işlem elemanı ya da proses elemanı olarak isimlendirilen çok sayıda basit işlem biriminden oluşmaktadır. Biyolojik sinir ağlarının hücrelerine benzer şekilde yapay sinir ağlarının da yapay sinir hücreleri bulunmaktadır. Yapay sinir ağları, basit biyolojik sinir sisteminin çalışma prensibini simüle etmek adına geliştirilen bir programdır. Yapay sinir ağları, simüle edilen sinir hücrelerini içermektedir ve bu hücreler farklı şekillerde birbirlerine bağlanarak ağı oluşturmaktadır. Şekil 1'de genel bir yapay sinir hücresinin yapısı sunulmaktadır (Yurtoğlu, 2005: 14).



Şekil 1: Yapay Sinir Hücresi Yapısı

Kaynak: Yurtoğlu, 2005: 14.

Yapay bir nöron olan j'nin görevi basittir. Komşu nöronlardan gelen giriş sinyallerini ( $x_i$ ) alır. Bu ağırlıklı sinyallerin toplamı, nöronun toplam veya net girişini ( $net_j$ ) sağlar. Daha sonra, pozitif veya negatif bir  $y_j$  değeri ile temsil edilen nöron j'nin aktivasyon eşiği, net girişe eklenir ve bir matematiksel fonksiyon  $f()$  (genellikle doğrusal olmayan ve bir aktivasyon fonksiyonu) net girişine, çıkış değeri  $y_j$ 'ye uygulanır. Hesaplanır ve diğer nöronlara gönderilir (Palmer et al., 2006: 782-783).




**Şekil 2:** Yapay bir nöronun genel işleyişi

**Kaynak:** Palmer vd., 2006: 783.

### 3.3.2. Biyolojik Sinir Hücreleri

Beynimizin çalışma sistemi, günümüzde bile tam olarak çözülemeyen bir yapıdadır. Özellikle, insan vücudunun diğer organlarında yer alan hücrelerin aksine farklı şekilde yenilenme özelliği bulunmayan beyin insana; hatırlama, düşünebilme ve eski tecrübelerle başvurabilme yeteneğini sunan sinir hücrelerinin işleme prensibi hala büyük oranda bilinmemektedir. Bir insan beyininde ortalama 1010 sinir hücresi ve bu hücrelerin de 6x1010'dan fazla bağlantıya sahip olduğu bilinmektedir. İnsan beyninin gücü ise; hayli çok olan bu sinir hücreleri ve aralarında bulunan bağlantıların genetik yapıları yardımıyla öğrenme yeteneğidir (Yücesoy, 2011: 40).



**Şekil 3:** Biyolojik Sinir Hücresi Yapısı

**Kaynak:** Basheer ve Hajmeer, 2000: 3.





### 3.3.3. Biyolojik Sinir Hücreleri ile Yapay Sinir Hücrelerinin Karşılaştırılması

Beyin ve sinir sisteminin özellikleri, içsel yapısı ve çalışma sisteminin bilinmemesi bu konuda sağlıklı bir karşılaştırma yapılmasını zorlaştırmaktadır. Fakat, teknoloji ve bilgisayar ağlarında meydana gelen ilerlemeler insan beyni ve sinir sisteminin araştırılmasında ilerlemelere olanak sağlamıştır. Yapay sinir ağları tekniğinin geliştirilmesiyle belli düzeyde sinir sistemini taklit eden modeller tasarlanmaya başlamıştır. Sinir sistemi ve beyin hakkında sağlanan bilgi artışı ise daha sağlıklı karşılaştırmalar yapılması mümkün olabilecektir. Aşağıda yer alan Tablo 1’de, biyolojik sinir hücresinin elemanlarına karşılık gelen yapay sinir hücresi elemanları gösterilmektedir (Ballı, 2014: 76).


**Tablo 1:** Biyolojik-Yapay Sinir Hücresi Elemanlarının Karşılıkları

| İşlem Birimi        |                       |                                                      |
|---------------------|-----------------------|------------------------------------------------------|
| Biyolojik Sinir Ağı | Yapay Sinir Ağı       | Görevleri                                            |
| Dendrit             | Alıcı ve Toplayıcı    | Çevreden gelen veriyi alır                           |
| Akson               | Verici                | Gövdenin oluşturduğu veriyi iletir                   |
| Hücre gövdesi       | Aktivasyon Fonksiyonu | Gelen veriyi toplayarak yorumlar ve veriyi oluşturur |
| Sinaptik Ağlar      | Bağlantı Aralıkları   | Öğrenilenleri hücrede saklar                         |

**Kaynak:** Ballı, 2014: 76.

### 3.3.4. Yapay Sinir Ağları Yönteminin Temel Yapısı

Bir yapıyı dizayn edebilmenin en basit yolu elemanları katmanlandırmaktan geçmektedir. Bu sürecin üç bölümü bulunmaktadır. Bu bölümler; nöronları katmanlar şeklinde gruplandırmak, katmanlar arasındaki bağlantıları gruplandırmak, toplama ve transfer fonksiyonlarını gruplandırmak şeklindedir. Bir başka ifadeyle, sinir hücrelerinin bir araya gelmesi rastgele olamaz. (Öztemel, 2006: 52; Gorr et al., 1994: 19-20);



Şekil 4. YSA Yapısı


**Kaynak:** Öztemel, 2006: 53.

*Girdiler* Bu katman içerisindeki nöronlar, dış çevreden bilgi edinerek gizli katmanlara transfer ederler. Bazı ağlarda girdi katmanında herhangi bir bilgi işleme olmamaktadır. Sadece girdi değerlerini sonraki katmana iletirler. Bundan dolayı bazı araştırmacılar, bu katmanı ağların katmanları içerisinde ilave etmezler (Collins ve Clark, 1993: 506-507).

*Ağırlıklar* gelen bilgilerin hücre üzerindeki etkisini belirleyen değerlerdir. Her giriş için bir ağırlık bulunmaktadır. Ağırlığın büyük olması girişin önemli olduğu veya ağırlığın küçük olması girişin önemsiz olduğu anlamına gelmez, bazen bir girişin ağırlığının sıfır olması o ağ için en önemli olay olabilir. Aynı şekilde negatif değerler de yine girişin önemi ile ilgili bilgi vermemektedir, ağırlığın artı ve eksi olması girişin etkisinin pozitif veya negatif olduğunu göstermektedir. Ayrıca ağırlıklar değişken veya sabit de olabilmektedirler (Atasoy, 2012: 50).

*Gizli (Ara) Katman;* girdi katmanından elde edilen bilgiler işlenilerek çıktı katmanına gönderilmektedir. Bu bilgilerin işlenmesi gizli katmanlarda gerçekleştirilmektedir. Standart bir ağ içerisinde girdi ve çıktı katmanları tek katmandan oluşmaktayken, gizli katman miktarı birden fazla olabilmektedir. Gizli tabakalar çok sayıda nöron içermektedir ve bu nöronlar diğer nöronlarla bağlantılıdır. Ağın büyüklüğünün tanımlanması ve performansın bilinmesi açısından gizli katmanda bulunan nöronların sayısının seçimi oldukça önemlidir. Ayrıca gizli katmandaki nöronların ve katmanların sayısının artırılması veya azaltılması ağın basit veya karışık yapıda olmasını etkilemektedir (Curry ve Moutinho, 1993: 9-10).

*Toplama Fonksiyonu,* bir hücreye gelen net girdiyi hesaplamaktadır. Bu hesaplama esnasında farklı fonksiyonlar kullanılabilir. Bu fonksiyonlardan en çok tercih edileni ağırlıklı toplamı



bulmaktır. Burada, gelen her bir girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece, ağa gelen net girdi hesaplanabilmektedir. Bir işlem elemanın gerçekleştirdiği ilk faaliyet, tüm girdilerin ağırlıklandırılmış toplamlarını hesaplamaktır. Matematiksel olarak; girdiler (X) ve ağırlıklar (W) vektörlerdir. Toplam girdi sinyali, bu iki vektörün oluşturduğu noktadır (Atasoy, 2012: 51).

*Aktivasyon fonksiyonu*, toplama fonksiyonundan gelen girdiyi işlemekte ve yapay sinir hücresinin çıkışını belirlemektedir. Transfer fonksiyonu adıyla da bilinen aktivasyon fonksiyonu, farklı tiplerde ve genelde doğrusal olmayan bir fonksiyondur. Doğrusal fonksiyonların tercih edilmemesinin sebebi, doğrusal fonksiyonlarda girdiyle çıktının doğru orantılı olmasından kaynaklanmaktadır. Bu durum, ilk yapay sinir ağları denemelerinin başarısızlıkla sonuçlanmasının temel sebebidir (Atasoy, 2012: 51).

*Çıktı Katmanı*: Bu katmanda yer alan nöronlar, gizli katmandan alınan bilgileri işleyerek ağırlıklandırılmış girdi katmanından sunulan girdi seti (örnek) için üretmesi gereken çıktıyı üretmektedirler. Üretilen çıktı dış dünyaya gönderilmektedir (Fletcher ve Goss, 1993: 162).

#### 4. Gıda Sektöründe Talep Tahmin Yöntemleri Uygulaması

Gıda sektöründe faaliyet gösteren firmada yapılan uygulamada Chandler türü ithal iç ceviz ele alınmıştır. Ceviz sofralarımızda oldukça önemli bir yere sahiptir. Tatlı sektörünün vazgeçilmezi olmasının yanı sıra ham haliyle de tüketimi oldukça fazladır. Diyet programlarının adeta vazgeçilmezi olan ceviz her kesimden tüketiciler için takviye gıda olarak tüketilmektedir. İsminin gizli tutulmasını isteyen şirket başta Marmara bölgesi olmak üzere tüm Türkiye'ye satış yapmaktadır. Ele aldığımız şirket bu ürünün ithalatçısı konumundadır. Ceviz saklanması oldukça zahmetli bir ürün olmasının yanı sıra beklemesi halinde ise kalite kaybı azımsanamayacak derecededir. Oldukça maliyetli olan bu ürün için talebe ilişkin tahminlerin önemini arttırmaktadır.

##### 4.1. Regresyon Yöntemi

Regresyon yöntemi, bağımsız değişken ya da değişkenlerin aldığı değerler karşısında bağımlı değişken değerinin kurulan regresyon modeline göre hesaplanarak tahmin edilmesi işlemidir (Sarı, 2014: 1).

Şirketin ERP sisteminden alınan veriler SPSS 20.0 programı kullanılarak çoklu regresyon analizi yapılmıştır. Yapılan analiz sonucunda bağımlı ve bağımsız değişkenlerin ortalamaları ve standart sapmaları hesaplanmıştır.



**Tablo 2:** Regresyon Analizi Betimleyici İstatistikler Tablosu


|                | Talep   | Fiyat | Kur  | Müşteri | Enflasyon | Rakip |
|----------------|---------|-------|------|---------|-----------|-------|
| Ortalama       | 2275,5  | 38,74 | 2,69 | 111,4   | 8,27      | 16,08 |
| Standart Sapma | 1580,35 | 6,51  | ,64  | 11,76   | ,83       | 3,84  |

Bağımlı değişken olan talebin standart sapması 2275,5, ortalaması 1580,35 olarak hesaplanmıştır. Kur değişkeni standart sapması 0,64, ortalaması 2,69, enflasyon değişkeni standart sapması 0,83, ortalaması 8,27, rakip değişkeni standart sapması 3,84 ortalaması 16,08, müşteri değişkeni standart sapması 11,76, ortalaması 111,4, fiyat değişkeni standart sapması 6,51, ortalaması 38,74 olarak hesaplanmıştır.

**Tablo 3:** Regresyon Analizi Özet Tablosu

| Model | R    | R Kare | Düzeltilmiş R Kare |
|-------|------|--------|--------------------|
| 1     | ,662 | ,438   | ,386               |
| 2     | ,661 | ,437   | ,396               |
| 3     | ,657 | ,432   | ,401               |

Oluşturulan çoklu regresyon modelinde anlamlı çıkmayan bağımsız değişkenler backward yöntemiyle modelden çıkarılmıştır. Modelden 2 bağımsız değişken çıkarılmış olup bu değişkenler rakip ve enflasyon bağımsız değişkenleridir. Modelde yer alan bağımsız değişkenlerin kur, müşteri ve fiyat bağımsız değişkenlerinin bağımlı değişkeni açıklama oranı %40,1 olarak hesaplanmıştır.

**Tablo 4:** Regresyon Analizi Anova Tablosu

| Model   |           | Ortalama<br>Kare | F      | Sig. |
|---------|-----------|------------------|--------|------|
| Model 1 | Regresyon | 12903686,53      | 8,412  | ,000 |
|         | Artıklar  | 1533982,45       |        |      |
| Model 2 | Regresyon | 16106781,59      | 10,683 | ,000 |
|         | Artıklar  | 1507751,98       |        |      |
| Model 3 | Regresyon | 21202261,47      | 14,178 | ,000 |
|         | Artıklar  | 1495476,8        |        |      |

Oluşturulan istatistiksel olarak anlamlı modelin F değeri 14,178 olarak hesaplanmış olup anlamlılık değeri ise 0,000 olarak hesaplanmıştır. Bu değerler bize modelin istatistiksel olarak anlamlı olduğunu ve kullanılabilirliğini göstermektedir. Modelin artık kareler toplamı 83746700,604 olarak hesaplanmış buna bağlı olarak MSE değeri 1495476,797 olarak hesaplanmıştır.

**Tablo 5:** Regresyon Modeli Katsayı Tablosu

| Model |         | Sabit      | Fiyat   | Kur       | Müşteri | Enflasyon | Rakip |
|-------|---------|------------|---------|-----------|---------|-----------|-------|
| 1     | Katsayı | -12659,999 | 230,266 | -1613,017 | 108,496 | -229,607  | 10,74 |
|       | Sig     | ,003       | ,013    | ,023      | ,000    | ,453      | ,808  |
| 2     | Katsayı | -12385,418 | 224,525 | -1579,477 | 108,091 | -220,507  | -     |
|       | Sig.    | ,002       | ,012    | ,022      | ,000    | ,464      | -     |
| 3     | Katsayı | -13078,253 | 183,776 | -1362,275 | 106,861 | -         | -     |
|       | Sig.    | ,001       | ,007    | ,026      | ,000    | -         | -     |

Oluşturulan çoklu regresyon modelindeki istatistiksel olarak anlamlı olmayan bağımsız değişkenler modelden backward yöntemiyle çıkarılmıştır. Model 3 adımda oluşturulmuş olup ilk aşamada bütün bağımsız değişkenler yer almaktadır. 2. aşamada rakip bağımsız değişkeni çıkarılarak tekrar kurulmuştur. Rakip ve enflasyon bağımsız değişkenleri istatistiksel olarak anlamlı bulunamamış olmasına rağmen rakip değişkeninin significance değeri daha yüksek olması modelden ilk onun atılmasına neden olmuştur.




Elde edilen çoklu regresyon modeli sabit ve bağımsız değişkenlerden kur, müşteri ve fiyat olarak oluşmuştur. Sabit terimin katsayısı -13078,25, kur değişkeninin katsayısı -1362,28, müşteri değişkeninin katsayısı 106,86, fiyat değişkeninin katsayısı 183,78 olarak hesaplanmıştır.

$$Talep = -13078,25 - 1362,28 Kur + 106,86 Müşteri Sayısı + 183,78 Fiyat \quad (3)$$

3'deki denklem ile hesaplanan talep değerlerinin hataları MSE 3831146, MAPE 143,02 olarak hesaplanmıştır.


**Şekil 5:** Regresyon Modeliyle Tahmin Edilen Değerler İle Gerçek Değerlerin Grafiği



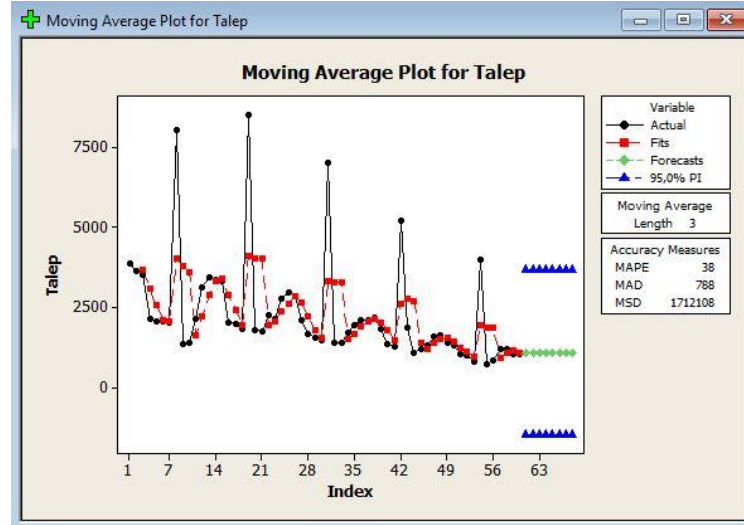
Regresyon modeli ile tahmin edilen değerler ve gerçek değerlerin yer aldığı grafik şekil 5'de gösterilmiştir. Modelin açıklayıcılık açısından düşük değerlere sahip olması modelin ortaya çıkardığı tahmin sonuçlarını açıklar niteliktedir.

#### 4.2. Hareketli Ortalamalar Yöntemi

Hareketli ortalamalar sık kullanılan talep tahmin yöntemlerinden bir tanesidir. Bu bölümde elimizde bulunan aylık ortalama ceviz talebine ilişkin veriler için hareketli ortalamalar yöntemiyle tahmin yapılacaktır. Yapılacak olan tahminler için şirketin ERP sisteminden alınan veriler Minitab 15.0 programında işlenerek tahminler yapılacaktır.




Şekil 6: 3'lü Hareketli Ortalama Grafiği



3'lü Hareketli ortalama ile yapılan analizde MAPE değeri 38, MSE 1712108 olarak hesaplanmıştır. Bu yöntemle 8 dönemlik tahmin yapılmış olup bu tahminlere ait MAPE değeri 29, MSE değeri ise 1521263 olarak hesaplanmıştır.

Şekil 7: 3'lü Hareketli Ortalama Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Değerlerinin Grafiği



Şekil 7'de 3'lü hareketli ortalamalar yöntemiyle hesaplanan tahmin değerleri ile gerçek değerler aynı grafikte gösterilmektedir. Bir sonraki dönem için sağladığı tahmin tutarlılığını sonraki dönemler için göstermediği görülmektedir. Birden fazla dönem için bu model ile tahmin bu çalışma için yetersiz kalacaktır. Benzer şekilde, 4, 5 ve 6 lı hareketli ortalamalar yöntemleri de kullanılmıştır.


#### 4.3 Winters Üstel Düzeltme Yöntemi

Winters üstel düzeltme yöntemi modeli de kurulmuş ve tahmin yapılmıştır. Modelin kurulması esnasında ortaya çıkan hata değerlerinden olan MAPE değeri 37, MSE değeri ise 124885474,6 olarak hesaplanmıştır. Toplamda 68 veriden oluşan veri setinin 60 adet verisi ile model kurulmuş ve hata terimleri hesaplanmıştır. Kalan 8 adet veri ise modelin tahmin ettiği değerler ile karşılaştırılmış ve hata



değerleri hesaplanmıştır. Bu hesaplamalar sonucu MAPE değeri 28,83, MSE değeri 1222917 olarak bulunmuştur.

**Şekil 8:** Winters' Üstel Düzeltme Yöntemiyle Hesaplanan Tahmin Değerleri İle Gerçek Talep Değerlerin Grafiği



Winters' üstel düzeltme yöntemiyle kurulan model yardımıyla hesaplanan değerler ile gerçek talep değerleri şekil 8'deki grafikte gösterilmiştir. Model, bir noktada gerekli tepkiyi vererek yükseliş trendinin olduğu noktada bir yükselme eğilimi gösterse de gözlenen aykırı değeri hesaplama yetersiz kalmıştır.

#### 4.4. Yapay Sinir Ağları İle Talep Tahmin Yöntemi

##### *Değişkenlerin Tanımlanması*

Satış ve pazarlama ekibi ile yapılan görüşmeler ile ceviz talebini etkileyen çok sayıda bağımsız değişken olduğu belirlenmiş olup bu değişkenler hakkında sayısal veri veya aylık sayısal veri elde etmek pek mümkün değildir.

Uygulamanın bağımlı değişkeni aylık ceviz talebi miktarıdır. Satış ve pazarlama ekibi ile yapılan görüşmeler ile ithal ceviz talebini etkileyen bağımsız değişkenler ise şunlardır:

- Satış fiyatı ortalaması
- Rakip firma sayısı
- Müşteri sayısı
- Dolar kuru ortalaması (Aylık)
- Enflasyon



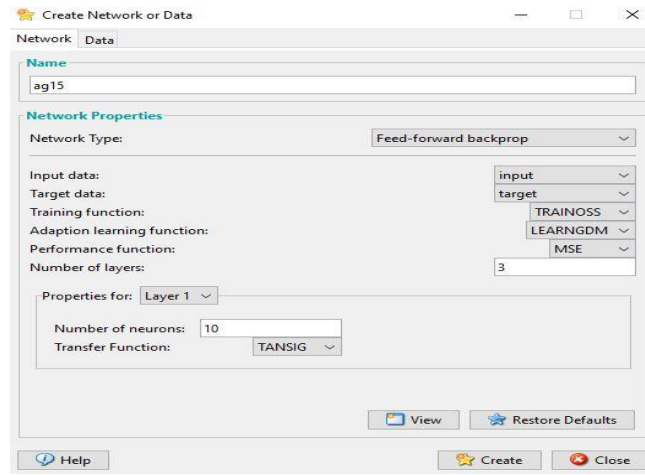


#### 4.4.1. Modelin Tasarlanması

Uygulamada kullanılan ağ literatürde sıkça bahsedilen ileri beslemeli geri yayımlı yapay sinir ağı tercih edilmiştir. İleri beslemeli geri yayımlı yapay sinir ağının kullanım amacı tahmin çalışmalarında sıklıkla kullanılması ve tahminlerdeki başarısıdır. Yapay sinir ağı modeli Matlab R2019a programı kullanılarak oluşturulmuştur.


Şekil 9'da görüldüğü üzere modelin transfer fonksiyonu tanjant sigmoid, eğitim fonksiyonu trainoss kullanılmıştır. Performans fonksiyonu hata kareleri ortalaması (MSE), ortalama mutlak yüzde hata (MAPE) kullanılmıştır.

Şekil 9: Matlab Yapay Sinir Ağı Oluşturulması



Çalışmada tasarlanan yapay sinir ağı modelinde, 5 girdi ve 1 çıktı değişkeni bulunmaktadır. Oluşturulan modelde şekil 3.16'da gösterildiği gibi, girdi katmanı, 2 gizli katman ve 1 çıktı katmanı bulunmaktadır. Gizli katman sayısı ve her katmanda yer alan nöron sayısı denemeler sonucunda belirlenmiştir.

Şekil 10: Yapay Sinir Ağı Modeli

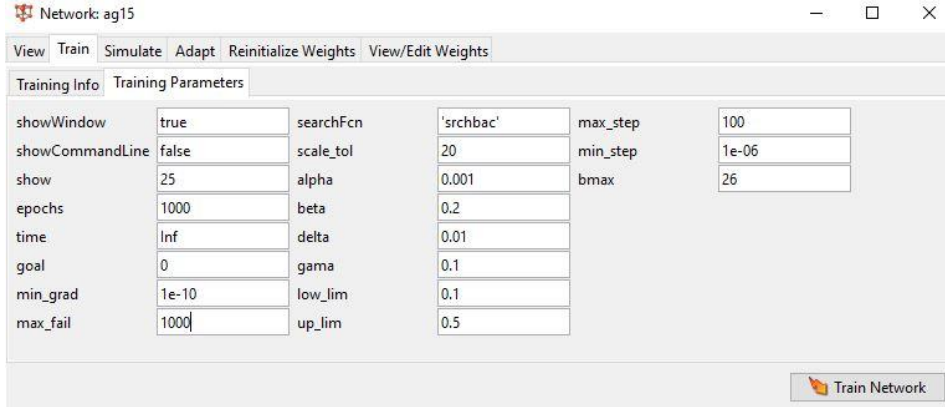




#### 4.4.2. Talep Tahmin Uygulaması


Oluşturulan ağı eğitimi için çeşitli algoritma ve fonksiyonlar vardır. Bunlardan en uygun olanı deneme yanılma yöntemi ile bulunmuştur. Uygunluğu  $R^2$  değerinin en büyük olanı, MSE değerlerinin ise en küçük olması belirlemektedir.

Şekil 11: Eğitim Algoritması Parametreleri




Trainoss eğitim algoritması ağırlık ve yanlılık değerlerini, kesişen her adımda güncelleyen algoritmadır. İterasyon sayısı 1000, maksimum doğrulama hatası 1000, alfa katsayısı 0,001, beta katsayısı 0,2, delta katsayısı 0,01, gamma katsayısı 0,1 ve diğer değerleri varsayılan olarak ağı eğitilmiştir.

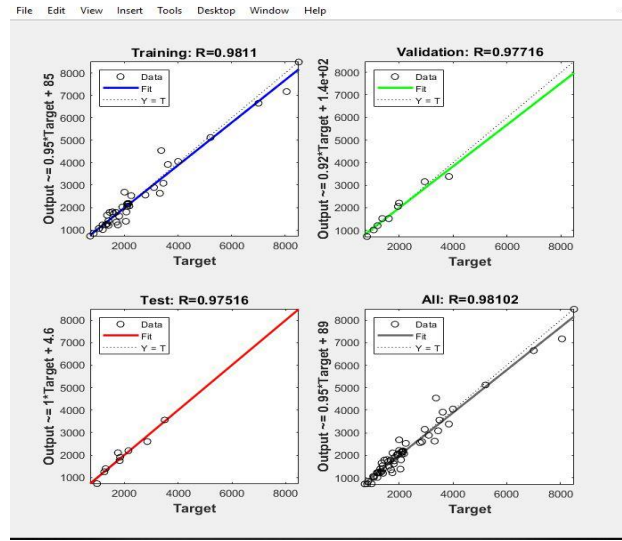
Şekil 12: Yapay Sinir Ağı Eğitimi Performans Grafiği



Eğitimi tamamlanan ağı sonucunda ortaya performans grafiği şekil 3.18'de görüldüğü üzere 7 iterasyonda en iyi değere ulaşmıştır. Henüz ezberleme yapmamış olması genelleme yapması açısından olumlu olacaktır.



Şekil 13: Ağ Eğitiminde Regresyon Değerleri




Eğitilen ağın regresyon değerleri şekil 13’de görülmektedir. Eğitim regresyon değerinin 0,9811 gibi yüksek bir değere sahip olması eğitim aşamasındaki başarıyı göstermektedir. Regresyon değeri 1’e ne kadar yakınsa söz konusu aşama o kadar başarılıdır. Doğrulama ve test aşamalarındaki regresyon değerleri de oldukça iyi olması ağı eğitim sürecinin başarılı geçtiğini göstermektedir.  $R^2$  değeri 1’e ne kadar yakınsa modelin açıklama oranı o kadar iyidir. 0,9624 olan modelin açıklama oranı oldukça iyi olup eğitim sürecinin başarısını teyit etmektedir. Yapay sinir ağı modelinde eğitim esnasında üretilen talep değerleri tablo 6’da verilmektedir.

Tablo 6: Eğitim Çıktıları

| Aylar   | 2013     | 2014     | 2015     | 2016     | 2017     |
|---------|----------|----------|----------|----------|----------|
| Ocak    | 3383,837 | 3082,883 | 3155,339 | 2048,331 | 1524,863 |
| Şubat   | 3916,266 | 4539,802 | 2600,757 | 2068,727 | 1394,286 |
| Mart    | 3560,687 | 2630,171 | 2127,93  | 1749,816 | 1067,04  |
| Nisan   | 2179,821 | 2212,883 | 1783,272 | 1272,987 | 727,75   |
| Mayıs   | 1385,167 | 2058,311 | 1807,359 | 1252,173 | 729,168  |
| Haziran | 1796,629 | 1614,472 | 1783,611 | 5121,837 | 4052,071 |
| Temmuz  | 2683,862 | 8485,27  | 6649,021 | 1902,041 | 725,3835 |
| Ağustos | 7169,036 | 2102,9   | 1409,02  | 1017,911 | 844,9968 |
| Eylül   | 1657,981 | 1225,384 | 1403,429 | 1206,338 | 1014,568 |
| Ekim    | 1200,732 | 2529,722 | 1349,425 | 1234,529 | 1223,935 |
| Kasım   | 2193,927 | 2177,439 | 2020,609 | 1718,388 | 1062,427 |
| Aralık  | 2888,817 | 2559,085 | 2164,51  | 1520,141 | 1061,902 |



**Şekil 14: YSA Çıktısı İle Gerçek Değerlerin Gösterimi**



Ağ çıktıları ile gerçek değerleri aynı grafikte gösterimi Şekil 14'de görülmektedir. Gerçek değerler ile ağ çıktısının arasındaki fark ağ çıktılarındaki başarıyı ortaya koymaktadır.

#### 4.4.3. Yapay Sinir Ağları Tahmin Sonuçları

Başlangıçta bulunan 68 adet veriden 60 adedi oluşturulan yapay sinir ağı modeli için kullanılmıştır. Kalan 8 adet veri ağı hiç gösterilmemiştir. Tablo 7'deki bu veriler ile oluşturulan yapay sinir ağının tutarlılığının ölçülmesi hedeflenmektedir.

**Tablo 7: Ağın Tutarlılığı İçin Kullanılacak Veri Seti**

| Aylar   | Kur   | Enflasyon | Rakip | Müşteri | Fiyat | Talep |
|---------|-------|-----------|-------|---------|-------|-------|
| Ocak    | 3,772 | 11,23     | 14    | 102     | 62    | 1250  |
| Şubat   | 3,778 | 11,23     | 13    | 100     | 62    | 1170  |
| Mart    | 3,881 | 11,14     | 10    | 99      | 62    | 1040  |
| Nisan   | 4,054 | 11,06     | 10    | 83      | 66    | 840   |
| Mayıs   | 4,414 | 11,1      | 13    | 76      | 68    | 790   |
| Haziran | 4,628 | 11,49     | 14    | 97      | 68    | 4500  |
| Temmuz  | 4,748 | 12        | 10    | 70      | 70    | 820   |
| Ağustos | 5,73  | 12,61     | 10    | 102     | 75    | 1600  |
| Eylül   | -     | -         | -     | -       | -     | -     |
| Ekim    | -     | -         | -     | -       | -     | -     |
| Kasım   | -     | -         | -     | -       | -     | -     |
| Aralık  | -     | -         | -     | -       | -     | -     |



Tablo 7’deki kur, enflasyon, rakip, müşteri ve fiyat değişkenleri yapay sinir ağının girdi değerlerini oluşturacaktır. Eğitilmiş olan yapay sinir ağı modeline daha önceden ağın görmediği girdi değerleri girilerek gelecek 8 aya ilişkin talep tahmin edilmiştir. Tablo 8’de gerçek değerler ile modelin tahmin ettiği talep değerleri ve arasındaki fark görülmektedir.

**Tablo 8:** Tahminlenen Talep İle Gerçek Talep Arasındaki Fark

| Aylar   | Gerçek Talep | YSA Talebi | Fark     |
|---------|--------------|------------|----------|
| Ocak    | 1250         | 1264,144   | -14,1436 |
| Şubat   | 1170         | 1007,888   | 162,1123 |
| Mart    | 1040         | 983,414    | 56,58597 |
| Nisan   | 840          | 891,6171   | -51,6171 |
| Mayıs   | 790          | 868,6808   | -78,6808 |
| Haziran | 4500         | 3831,623   | 668,3768 |
| Temmuz  | 820          | 798,1723   | 21,8277  |
| Ağustos | 1600         | 1306,323   | 293,6771 |
| Eylül   | -            | -          | -        |
| Ekim    | -            | -          | -        |
| Kasım   | -            | -          | -        |
| Aralık  | -            | -          | -        |

Gerçekleşen talep ile modelin tahmin ettiği talebin grafiksel gösterimi şekil 3.21’de gösterildiği gibidir. Tahminlenen talep ile gerçek talep değerleri arasındaki farkın çok az olduğu açıkça görülmektedir. Talebi etkileyen çok fazla değişkenin bulunması ve ayrıca talep döneminin doğrusal olmayışı yapay sinir ağı modeli performansı hakkında oldukça olumlu görünmektedir.



**Tablo 9:** Oluşturulan Modellerin Hata Terimleri Tablosu

| Yöntem                  | MSE         | MAPE   |
|-------------------------|-------------|--------|
| Regresyon               | 3831146,032 | 143,02 |
| 3'lü Hareketli Ortalama | 1521262,514 | 29,006 |
| 4'lü Hareketli Ortalama | 1519542,188 | 29,062 |
| 6'lı Hareketli Ortalama | 1412512,5   | 35,075 |
| Tekli Üstel Düzeltme    | 1350848     | 54,78  |
| İkili Üstel Düzeltme    | 1819814     | 25,62  |
| Winters' Metodu         | 1222917     | 28,83  |
| Yapay Sinir Ağları      | 71498,462   | 9,05   |

Tablo 9'da uygulamada oluşturulan modellerin hata terimlerini görebiliriz. Oluşturulan regresyon modeline ait MSE değeri 3831146,032 iken MAPE değeri 143 çıkmıştır. Hareketli ortalamalardan 3, 4 ve 6'lı hareketli ortalamalar sonucunda tahmin modeli oluşturulmuştur. 3'lü hareketli ortalamalar yöntemi ile yapılan tahminin hataları MSE 1521262,514, MAPE 29,006 değerleri olarak hesaplanmıştır. 4'lü hareketli ortalamalar yöntemi ile yapılan tahminin hataları MSE 1519542,188 MAPE 29,062 değerleri olarak hesaplanmıştır. 6'lı hareketli ortalamalar yöntemi ile yapılan tahminin hataları MSE 1511412512,5 MAPE 35,075 değerleri olarak hesaplanmıştır.

Uygulamada kullanılan bir diğer yöntem olan üstel düzeltme yöntemlerinden tekli, ikili ve winters üstel düzeltme yöntemleri kullanılmıştır. Kullanılan bu yöntemlerin hesaplanan hata terimleri tablo 9'da verilmiş olup tekli üstel düzeltme yönteminin hesaplanan hata terimleri MSE 1350848 ve MAPE 54,78 olarak bulunmuştur. İkili üstel düzeltme yöntemi ise MSE 1819814 ve MAPE 25,62 sahip tahminler üretmiştir. Winters' metoduna ait tahminlerin hata terimi değerleri ise MSE 1222917 ve MAPE 28,83 olarak hesaplanmıştır. Bir diğer yöntem olan yapay sinir ağlarına ait hata terimi değerleri de Tablo 9'da yer almaktadır. Yapay sinir ağının tahminine ilişkin hata terimi değerleri ise MSE 71498,462 ve MAPE 9,05 bulunmuştur. Yapay sinir ağları yöntemi diğer yöntemlerden açık ara daha iyi olduğunu hata terimlerinden görebilmekteyiz.

## 5.SONUÇ

Günden güne değişen dünyamızda insan ihtiyaçları da değişmekte ve çeşitlenmektedir. Toplumlar önceleri fazla beklentisi olmayan, sahip olduklarıyla yetinen fazla seçeneği olmayan bir anlayışa sahiplerdi. Gelişen dünyada tüketici anlayışları hızla değişmekte ve dolayısıyla daha bilinçli ve



bilinçlenmeye devam eden tüketicilerden oluşan bir toplumsal yapı oluşmaya başlamaktadır. Tüketici ihtiyaçları ise demografik, psikolojik, sosyokültürel, coğrafi ve tüketiciye sağladığı faydalara göre çeşitlilik göstermektedir. İhtiyaçları tespit edebilmek bu ihtiyaçlara göre ürün geliştirmek ya da mevcut ürünü talebe göre üretmek örgütler açısından büyük önem taşımaktadır. Talep tüketicilerin belirli bir dönemde belirli bir fiyat üzerinden satın almayı istedikleri ürünlerin miktarı olarak tanımlanabilir. Bir başka deyişle tüketicilerin mevcut bir ürünü ya da üretilmesi planlanan bir ürüne ilişkin satın alma istekliliği olarak açıklanabilir. Günümüzde çeşitlenen insan ihtiyaçları, talebe yönelik değişkenlerde de çeşitliliğe neden olmaktadır. Talebe etki eden faktörlerin çoğalması ve bu değişkenler arasındaki ilişkinin karmaşıklığı istatistiksel yöntemlere olan eğilimi arttırmıştır. İstatistiksel metotların başarısının, sezgisel metotların başarısına göre daha iyi sonuçlar verdiği literatürdeki araştırmalardan da görülebilmektedir.

Çalışmada kullanılan yapay sinir ağı 5 girdi ve 1 çıktı değişkeninden oluşmaktadır. Oluşturulan ağa 68 verinin 60 tanesi eğitim için kullanılmıştır. Ağın eğitimi başarı ile tamamlanmış ağın açıklama oranı %96,24 olarak hesaplanmıştır. 68 veriden kalan 8 veri ile yapay sinir ağına tahmin yaptırılmıştır. Elde edilen sonuçlar ile gerçek değerlerin farkından hesaplanan MAPE ve MSE değerlerine oranla çok düşük çıkmıştır. Tasarlanan bu modelin diğer yöntemlerden daha iyi sonuçlar verdiğini söyleyebiliriz. Şekil 3.21' görüldüğü üzere gerçek değerler ile tahmin değerleri arasındaki fark çok azdır. Tüm bu sonuçlar ışığında yapay sinir ağları ile kurulan modelin; regresyon, 3'lü, 4'lü ve 6'lı hareketli ortalamalar ve tekli üstel düzeltme, ikili üstel düzeltme ve winters' metodu üstel düzeltme yöntemlerinden bu çalışmada açık ara daha tutarlı tahminler yaptığı görülmektedir. Ayrıca çalışmada elde edilen model, şirketin bölgesel müşterileri taleplerinde kullanılarak stokların düzenlenmesi açısından da fayda sağlayabilir. Bu sayede işletmenin zaman kaybı ve ekstra taşıma maliyetinden kurtulması sağlanabilecektir.

Doğrusal olmayan serilerde yapay sinir ağları yöntemleri başarılı sonuçlar vermektedir. Araştırma konusunun daha da geliştirilebilmesi adına ilerleyen çalışmalarda parametrik olmayan regresyon analizi gibi yöntemlerle karşılaştırılabilir. Kısa vadeli tahminlerde oldukça iyi performans gösteren bu yöntem uzun vadeli tahminler açısından genetik algoritma yöntemiyle karşılaştırılması gelecekteki çalışmalar için farklı bir bakış açısı oluşturabilir.


## REFERENCES

- Altman, E.I., Marco, G. ve Varetto, F., (1994). Corporate Distress Diagnosis: Comparisons Using Linear Discriminant Analysis and Neural Networks (The Italian Experience)", Journal of Banking and Finance, 18(3), 505-529.
- Anderson, D. ve McNeill, G., (1992). Artificial Neural Networks Technology, A DACS State Of The Art Report, New York.



- Ataseven, B., (2013). Yapay Sinir Ağları İle Öngörü Modellemesi, Öneri Dergisi, 10(39), 101-115.
- Atasoy, S., (2012). Yapay Sinir Ağları ve Sinirsel Bulanık Ağlar İle İnsan Kaynaklarında Performans Yönetimi Modellenmesi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Aydın, M.Ç., (2017). Giyim Endüstrisinde Talep Tahmin Yöntemlerinin Uygulanması: Örnek Bir Uygulama, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Konya.
- Ballı, M.T., (2014). Yapay Sinir Ağları İle Talep Tahmini ve Gıda Sektöründe Uygulanması, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Basheer, I. and Hajmeer, M., (2000). Artificial Neural Networks: Fundamentals, Computing, Design and Application, Journal of Microbiological Methods, 43 (1), 3-31.
- Civalık, Ö. ve Ülker, M., (2004). Dikdörtgen Plakların Doğrusal Olmayan Analizinde Yapay Sinir Ağı Yaklaşımı, İMO Teknik Dergi, 15(72), 3171-3190.
- Çağlar, T., (2007). Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması, Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kırıkkale.
- Çetinel, S., (2005). Pazarlama Planı, Girişimciler İçin Yatırım Danışma ve Girişimcilik Geliştirme Merkezi Projesi, Ankara.
- Coats, P.K. ve Fant, L.F., (1993). Recognizing Financial Distress Patterns Using A Neural Network tool, Financial Management, 22(3), 142-155.
- Collins, J.M. ve Clark, M.R., (1993). An Application of The Theory of Neural Computation to The Prediction of Workplace Behavior: An illustration and assessment of network analysis, Personnel Psychology, 46(3), 503-524.
- Curry, B. ve Moutinho, L., (1993). Neural Networks In Marketing: Modelling consumer responses to advertising stimuli, European Journal of Marketing, 27 (7), 5-20.
- Demirbaş, F.P., (2011). Kombi Üretiminde Talep Tahmin Yöntemlerinin Uygulanması, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kocaeli.
- Detienne, K.B., Detienne, D.H. ve Joshi, S.A., (2003). Neural Networks as Statistical Tools for Business Researchers, Organizational Research Methods, 6 (2), 236-265.
- Efendigil, T., Önüt, S., ve Kahraman, C., (2009). A Decision Support System for Demand Forecasting With Artificial Neural Networks and Neuro-fuzzy Models: A Comparative Analysis, Expert Systems With Applications, 36, 6697-6707.
- Fildes, R., Goodwin, P. ve Lawrence, M., (2006). The Design Features of Forecasting Support Systems and Their Effectiveness, Decision Support Systems, 42 (1), 351-361.





- Fletcher, D. ve Goss, E., (1993). Forecasting With Neural Networks: An application using bankruptcy data, *Information and Management*, 24 (3), 159- 167.
- Gorr, W.L., Nagin, D. ve Szczypula, J., (1994). Comparative Study of Artificial Neural Network and Statistical Models for Predicting Student Grade Point Averages, *International Journal of Forecasting*, 10 (1), 17-34.
- Karaatlı, M. vd., (2012). Yapay Sinir Ağları Yöntemi İle Otomobil Satış Tahmini, *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8 (17), 87-100.
- Karahan, M., (2011), İstatistiksel Tahmin Yöntemleri: Yapay sinir ağları metodu ile ürün talep tahmini uygulaması, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, Konya.
- Kuan, C.M. ve White, H., (1994). Artificial Neural Networks: An econometric perspective, *Econometric Reviews*, 13 (1), 1-91.
- Kutlu, B. ve Badur, B., (2009). Yapay Sinir Ağları İle Borsa Endeksi Tahmini, İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadı Enstitüsü Dergisi - Yönetim, 20 (63), 25-40.
- Öztemel, E., (2006). Yapay Sinir Ağları, Papatya Yayıncılık, 2. Basım, İstanbul.
- Öztürk, H., (2006). Türkiye Yongalevha ve Liflevha Endüstrisinde Talep Tahmini Uygulamaları, Zonguldak Karaelmas Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Bartın.
- Palmer, A., Montano, J.J. ve Sese, A., (2006). Designing An Artificial Neural Network for Forecasting Tourism Time Series, *Tourism Management*, 27, 781–790.
- Sarı, B., (2014). Hisse Senetleri Getirilerinin Lojistik Regresyon ve Doğrusal Regresyon Modelleri İle Bir Analizi, Kadir Has Üniversitesi, Sosyal Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Silver E.A., Pyke, D.F. ve Peterson, R., (2000). *Inventory Management and Production Planning and Scheduling*, John Wiley Sons, 3th Edition, USA.
- Tang, T.C., ve Chi, L.C., (2005). Neural Networks Analysis In Business Failure Prediction of Chinese Importers: A Between-Countries Approach”, *Expert Systems With Applications*, 29, 244–255.
- Tokpunar, İ., (2014). Tedarik Zinciri Yönetiminde Talep Tahmin Doğruluğunu Arttırmak İçin Radar Diyagramının Kullanımı, Bahçeşehir Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Yurtoğlu H., (2005). Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı makroekonomik değişkenler İçin Türkiye örneği, DPT Uzmanlık Tezi, Ankara.
- Yücesoy, M., (2011). Temizlik Kağıtları Sektöründe Yapay Sinir Ağları İle Talep Tahmini, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.