



**T.C. İSTANBUL TİCARET  
ÜNİVERSİTESİ**

**FEN BİLİMLERİ ENSTİTÜSÜ**

**TÜRKİYE'DE PERAKENDE SEKTÖRÜNDE ELEKTRONİK  
ÜRÜNLERE OLAN TALEBİN YAPAY SİNİR AĞI İLE  
MODELLENMESİ**

**Didem VURAL**

**Danışman  
Doç. Dr. Berk AYVAZ**

**YÜKSEK LİSANS TEZİ  
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI  
İSTANBUL - 2019**

## KABUL VE ONAY SAYFASI

Didem VURAL tarafından hazırlanan "Türkiye’de Perakende Sektöründe Elektronik Ürünlere Olan Talebin Yapay Sinir Ağı İle Modellenmesi" adlı tez çalışması <sup>30/04/2019</sup> tarihinde aşağıdaki jüri üyeleri önünde başarı ile savunularak, İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda Yüksek Lisans Tezi olarak kabul edilmiştir.

Danışman

Doç. Dr. Berk AYVAZ  
İstanbul Ticaret Üniversitesi



Jüri Üyesi

Prof. Dr. Sibkat KAÇTIOĞLU  
İstanbul Ticaret Üniversitesi



Jüri Üyesi

Doç. Dr. Ali Osman KUŞAKÇI  
İbn Haldun Üniversitesi



Onay Tarihi : 09.07.2019



Prof. Dr. Necip ŞİMŞEK  
Enstitü Müdürü

## AKADEMİK VE ETİK KURALLARA UYGUNLUK BEYANI

İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Bu tezin herhangi bir bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

Tarih 09.07.2019

İmza

*Didem Vural*

**DİDEM VURAL**

## ÖNSÖZ

Gelişen teknoloji ile birlikte tüketici nüfusun teknoloji ve teknolojik ürünlere olan eğilimi de her geçen gün artan bir hal almaktadır. Buna paralel olarak perakende sektöründe talebi tahmin etmek birçok farklı değişkenin göz önünde bulundurulmasını gerektirmekte ve yalnız bununla kalmayıp bu değişkenlerin devamlılıklarını sağlamak adına da önlemler almak gerekmektedir. Günümüzde şartların dinamik olarak değiştiği perakende sektöründe tüketicilerden gelecek talep miktarını önceden tahmin edebilmek ve buna göre hızlı aksiyonlar alabilmek bir tercih değil zorunluluk halini almıştır.

Talebi tahmin etmek, onu etkileyen faktörleri iyi belirleyebilmek ve bu faktörlerin talebe olan etkisini öngörebilmek ile mümkün olmaktadır. Bu faktörlerin çeşitliliği ve dinamik değişkenliği ise bu tahminin yapılmasını daha karmaşık hale getirmektedir.

Dünyada teknoloji sektöründe meydana gelen gelişmeler ile birlikte talep tahmin çalışmaları için de çeşitli modelleme yöntemleri kullanılarak akıllıca sonuçlar elde edilebilmektedir. İnsanların bilgisayarları ve teknolojiyi etkin kullanması ile yapay zeka modeli çalışmalarda yerini almış ve son yıllarda bu model yapay sinir ağlarının kullanılmaya başlanmasına olanak sağlamıştır.

Bu çalışma kapsamında perakende sektöründe elektronik ürünlere olan talebin tahmini konusunda araştırmalar yapılmış ve yapay sinir ağları ile talep tahmini için bir model oluşturulmuştur.

Lisans ve yüksek lisans eğitimim süresince bana destek olan, bilgi ve deneyimleri ile bana yön veren Sayın Doç. Dr. Berk AYVAZ' a teşekkür ederim.

Didem VURAL  
İSTANBUL, 2019

# İÇİNDEKİLER

İÇİNDEKİLER.....	i
ÖZET.....	iii
ABSTRACT.....	iv
ŞEKİLLER.....	v
GRAFİKLER.....	vi
TABLolar.....	vii
ÇİZELGELER.....	viii
1. GİRİŞ.....	1
2. LİTERATÜR ÖZETİ.....	3
3. TALEP TAHMİNİ VE TAHMİN YÖNTEMLERİ.....	17
3.1.Talep Tahmini Kavramı.....	17
3.2. Talep Tahmin Adımları.....	18
3.3. Talep Tahmin Yöntemleri.....	19
3.3.1. Nitel yöntemler.....	19
3.3.2. Nicel yöntemler.....	21
3.3.4. Tahmin yöntemlerinin karşılaştırılması.....	22
3.3.5. Tahmin yöntemlerinin doğruluğunun ölçülmesi.....	23
4. YAPAY SİNİR AĞLARI.....	24
4.1. Tanım.....	24
4.2. Tarihsel Gelişim.....	25
4.2.1.Yapay sinir ağlarının kullanım alanları.....	25
4.3. Yapay Sinir Ağları Yapısı.....	26
4.4. Yapay Sinir Ağlarının Genel Özellikleri.....	28
4.4.1. Paralellik özelliği.....	28
4.4.2.Öğrenme, genelleme ve uyum sağlama özellikleri.....	28
4.4.3.Yüksek hata toleransı.....	29
4.4.4. Yapay sinir ağlarının dezavantajları.....	29
4.5.Yapay Sinir Ağlarında Öğrenme.....	29
4.5.1.Gözetimli öğrenme.....	31
4.5.2.Gözetimsiz öğrenme.....	32
4.5.3. Karma öğrenme.....	32
4.6.Yapay Sinir Ağlarında Öğrenme Kuralları.....	32

4.6.1. Hebb kuralı.....	33
4.6.2. Hopfield kuralı.....	33
4.6.3. Kohonen kuralı.....	33
4.6.4. Delta kuralı.....	34
4.7. Yapay Sinir Ağı Çeşitleri.....	34
4.7.1. İleri beslemeli ağlar .....	34
4.7.2. Geri beslemeli ağlar .....	35
4.8. Yapay Sinir Ağları Çalışma Prosedürü .....	35
4.9. Yapay Sinir Ağları ve Tahmin Modelleri.....	36
5. ELEKTRONİK PERAKENDE SEKTÖRÜNDE TALEP TAHMİNİ UYGULAMASI ..	39
5.1. Yapay Sinir Ağı Mimarisi.....	39
5.2. Yapay Sinir Ağı WEKA Uygulamaları .....	42
5.2.1. Yapay sinir ağlarının eğitimi ve testi .....	42
5.2.2. Öğrenme ve momentum katsayısının belirlenmesi .....	43
5.2.3. Çevrim sayısının belirlenmesi .....	44
5.2.4. Nöron sayısının belirlenmesi .....	44
5.2.5. Gizli hücre sayısının belirlenmesi .....	45
5.2.6. Seçilen tahmin modeli sonuçları .....	48
6. SONUÇ VE ÖNERİLER.....	51
KAYNAKLAR.....	55
ÖZGEÇMİŞ .....	61

## ÖZET

**Yüksek Lisans Tezi**

### **TÜRKİYE'DE PERAKENDE SEKTÖRÜNDE ELEKTRONİK ÜRÜNLERE OLAN TALEBİN YAPAY SİNİR AĞI İLE MODELLENMESİ**

**Didem VURAL**

**İstanbul Ticaret Üniversitesi  
Fen Bilimleri Enstitüsü  
Endüstri Mühendisliği Anabilim Dalı**

**Danışman: Doç. Dr. Berk AYVAZ**

**2019, 73 sayfa**

Şirketlerin başarıları geleceklerini tahmin etmedeki başarılarına bağlıdır. Bu yüzden talep tahmini şirketlerin kısa ve uzun dönemli hedeflerine ulaşmasında rol oynayan önemli bir faktördür. İlgili çalışmada yapay sinir ağları ile talep tahmini konusu ele alınmıştır. Bu bağlamda Türkiye'nin öncü elektronik perakende şirketlerinden birinin 'notebook' ürün grubu için geçmiş dönemlere ait satış verileri kullanılarak yapay sinir ağı ile gelecek dönemler için satış tahminlemesi yapılmıştır. Uygulama sonucunda yapay sinir ağı kullanılarak yapılan modellemede tahmin hataları karşılaştırılarak elde edilen sonuçlara ve değerlendirmelere yer verilmiştir.

**Anahtar Kelimeler:** Elektronik, perakende, talep tahmini, yapay sinir ağları.

## **ABSTRACT**

**M.Sc. Thesis**

### **FORECASTING THE DEMAND OF ELECTRONIC PRODUCTS BY ARTIFICIAL NEURAL NETWORKS IN TURKEY RETAIL SECTOR**

**Didem VURAL**

**Istanbul Commerce University  
Graduate School of Applied and Natural Sciences  
Department of Industrial Engineering**

**Supervisor: Prof. Dr. Berk AYVAZ**

**2019, 73 pages**

The success of the companies depends on their success in predicting their future. Therefore, demand forecasting is an important factor that helps companies to reach their short and long term goals. In this study, the problem of demand estimation with artificial neural networks is discussed. In this context, one of Turkey's leading electronic retail companies 'notebooks' product group sales data by using artificial neural network was carried past eras sales forecasting for future periods. As a result of the application of artificial neural network modeling using the estimation errors obtained by comparing the results and evaluations are given.

**Keywords:** Artificial neural networks, demand forecasting, electronic, retail.



## ŞEKİLLER

	<b>Sayfa</b>
Şekil 4.1. Yapay Sinir Ağı Yapısı.....	27
Şekil 6.1. Optimum Sonucun Gerçek Veri ile Karşılaştırılması.....	53



## GRAFİKLER

	<b>Sayfa</b>
Grafik 5.1. Geçmiş Aylara Ait Satış Adetleri.....	41
Grafik 5.2. Uygun Gizli Hücre ve Nöron Sayısı.....	47
Grafik 6.1. Optimal Sonuca Ait Yapay Sinir Ağı Yapısı.....	51



## TABLULAR

	<b>Sayfa</b>
Tablo 5.1. Gizli Hücre ve Nöron Sayısının Belirlenmesi için Denemeler .....	46
Tablo 5.2. Seçilen Modelde Kullanılan Eğitim Kümesi Verileri .....	49
Tablo 5.3. Seçilen Modelde Kullanılan Test Kümesi Verileri .....	50
Tablo 5.4. Modelde Kullanılan Eğitim ve Test Kümesi Verileri ile Tahmin .....	50



## ÇİZELGELER

	<b>Sayfa</b>
Çizelge 2.1. Talep Tahmini ile İlgili Örnek Modeller .....	11
Çizelge 3.1 : Tahmin Yöntemlerin Karşılaştırılması.....	22
Çizelge 4.1. Geleneksel Algoritma ile YSA Kıyası.....	26
Çizelge 6.1. Optimal Yapay Sinir Ağı Parametreleri.....	52
Çizelge 6.2. Gelecek 6 Aylık Tahmin Değerleri.....	52



# 1. GİRİŞ

Talep tahmini ve doğruluğunun bir işletmenin başarısı ve müşterisinin memnuniyeti ile doğrudan ilişkisi vardır. Talep tahmini yapılan ürünün değişkenliği ve talebi etkileyen faktörlerin zaman içindeki dinamikliği, bu ürünlerin talep tahmininin yapılmasını ve planlamayı güçleştirmektedir. Talep tahmininde rol oynayan bu güç yapıya karşılık etkin bir talep tahmini şirketi maksimum kara ulaştırırken, stratejik hedeflere mevcut kaynaklar ile ulaşmak kolaylaşacaktır.

Üretilen mal ve hizmet, buna bağlı olarak da talepte bulunan müşterinin değişken oluşu sebebiyle tek bir talep tahmin yönteminden bahsetmek olanaksızdır. Bu kapsamda talep tahmininde kullanılan yöntemler öznel ve nesnel olmak üzere ikiye ayrılırlar (Bolt, 1994). Öznel yöntemler, matematiksel verilerin kullanılmasına kıyasla daha çok tecrübeden yararlanan, yargılama ve zekaya dayanan yöntemlerdir. Nesnel yöntemler ise, daha farklı şekilde matematiksel verilerden oluşur. Optimal sonuç ise bu iki tip yöntemin birlikte kullanılmasıyla sağlanmaktadır (Tekin, 1996).

Yapay sinir ağları matematiksel ve istatistiksel olan verileri kullanmaktadır, sonrasında ise bileşenler arasındaki ilişkileri öğrenme algoritmasıyla çalışır. Veri kullanım stili ile nesnel yöntemlere, öğrenme özelliği ile ise öznel yöntemlere benzemesi sebebiyle verimli bir talep tahminleme metodu olarak günümüzde oldukça tercih edilmektedir. Çalışmamız kapsamında yapay sinir ağlarının etkin bir talep tahminleme yöntemi olduğu gösterilmeye çalışılmıştır.

Son zamanlarda talep tahmininde yapay sinir ağlarına sıklıkla başvurulmaktadır. İlgili çalışmamızda da yapay sinir ağları ile talep tahmini yapılmıştır ve Türkiye'nin perakende sektöründe önde gelen bir teknoloji şirketinin satış verilerinden yola çıkarak elektronik ürünler içinde önemli bir yeri olan notebook segmentli ürünler için talep tahmini üzerine çalışılmıştır.

Çalışmanın ikinci kısmında talebi tahmin etme üzerine ilgili literatür çalışmalarına yer verilmiştir. Üçüncü kısımda, biyolojik ve yapay sinir ağları konularında genel bir girişe yer verilerek yapay sinir ağları tanımı, tarihsel gelişim süreci, kullanım alanları, temel yapısı, yapay sinir ağlarının genel özellikleri, öğrenme mekanizması ve çeşitlerinden bahsedilmiştir. Uygulama kapsamında yapılan çalışmalar ayrıntılandırılarak talep tahmini yapılmış ve hata değerlerine göre sonuçları değerlendirilmiştir. Son bölümde ise uygulama aşamasında elde edilen sonuçlar değerlendirilerek gelecek çalışmalar için yön verebilecek iyileştirme önerileri sunulmuştur.



## 2. LİTERATÜR ÖZETİ

Literatürde talep tahminlemesi yapılırken çeşitli metodlar kullanılmıştır. Çalışmanın bu bölümünde literatürde talep tahmini yapılırken kullanılan yöntemler, mevcut çalışmamız kapsamında metod olarak yapay sinir ağı kullanılanlar ve yapay sinir ağı dışındaki yöntemler ile tahminleme yapılan çalışmalar olarak gruplandırılarak ilgili örnek makalelere yer verilmiştir. Çalışmalar değerlendirildiğinde yapay sinir ağı dışında kalan metodlar arasında ağırlıklı olarak regresyon, zaman serileri, Monte Carlo gibi simülasyon yöntemlerinin yer aldığı görülmektedir. Bu çalışmalar aşağıdaki gibi örneklendirilmiştir:

Carlson ve Umble (1980), örnek olarak Amerika’da, standart ve lüks otomobil segmentinde 5 farklı çeşit otomobilin, ilerideki 5 senelik talep tahminini bulmak için sunduğu çalışmasında, tahminleme yöntemi olarak çoklu regresyon analizini seçmiştir. Çalışmada, benzin fiyatı, benzin kıtlığının piyasaya etkisi, taşıt fiyatları, tüketici gelirleri ve sektördeki işçi grevlerinin talebi etkileyen etkenler olduğunu belirlemişlerdir.

Kauffman ve Sopariwala (1995), önerilerinde, pazar büyüklüğü değişkenleri ve pazar payı üzerindeki etkilerini kıyaslamışlardır.

Gavcar vd. (1999), sundukları “Türkiye’de Kullanılan Kağıt-Karton Türlerinin Talep Tahminlerinin Belirlenmesi” konulu çalışmalarında, SEKA kâğıt fabrikasının ürettiği 8 değişik kâğıt ürünün talebini tahminlemişlerdir. Araştırmalarında çoklu regresyon analizi kullanılmış ve değişkenlerin ilişkisi ise korelasyon analiziyle açıklanmıştır.

ZhoumcMahon vd. (2002), Avustralya'ya ait su tedarikinin Melbourne'de altı yıllık, günlük su tüketim verileri ile gelecek su talep tahminini zaman serileri ile açıklamışlardır.

Cahow (2004), çalışmasında tedavisi ev içerisinde yapılan kronik hastaların hemşire talebini Monte Carlo ve çoklu regresyon simülasyon yöntemleri ile tahmin etmişlerdir.

Matuyama vd. (2009), stok seviyesinin belirli olduğu ancak talep üzerinde kesinlik sağlamadığı vakalar için olan araştırmalarında iki farklı geribildirim politikasıyla regresyon ve zaman serileri gibi iki değişik tahmin yaklaşımı üzerinde durarak, stok sistemine periyodik bir açıdan yaklaşmışlardır.

Griffiths vd. (2010), çalışmalarında Regresyon ile yerel buğday verimliliği tahminlemesi yöntemiyle belirsiz bazı verileri analiz etmişlerdir.

Wei (2013), teknik analizin gelecekte hisse senedi fiyatının tahmin edilmesinde uygun bir yöntem olmakla beraber hisse senedi trendinin tahminlenmesinde teknik göstergelerin nasıl belirleneceği kısmının da önemli olduğunu belirtmiştir. Çalışmasında hisse senedi fiyatının tahmin edilmesi için ANFIS ve genetik algoritma modellerinden melez bir model oluşturmuştur. Karşılaştırma yapmak için ise ortalama hata kareleri kökünü kullanmışlardır.

Babic vd. (2014), seçilen havalimanına ait hava yolunun pazar payını etkileyen etmenlerin neler olduğu üzerine çalışmışlar ve pazar payını tahmin için bir yöntem ortaya koymuşlardır. İlk olarak seçilen havalimanında, bayrak taşıyan hava yollarına ait pazar payını etkileyen ana etmenleri çoklu lineer regresyon analizi ile bulmuşlardır. Bulunan parametreler ile, modellenen hava limanındaki



X bir hava yoluna ait pazar payının tahminlemesi için ise bulanık mantık uygulamışlardır.

Majhi ve Anish (2015), borsa tahminlemesinin oldukça önemli olduğunu vurgulamışlardır ve bu sebeple borsa tahmini için iki çok amaçlı model geliştirmişlerdir. Çok amaçlı parçacık sürüsü optimizasyonu ve genetik algoritma yöntemleri ile performans ölçütü seçtikleri dört adet ölçütün optimizasyonunu sağlayarak borsa tahmin modelini oluşturmuşlardır. Çalışmaları sonucunda uygun modelleri seçerken bulanık mantık tabanlı karar verme stratejisini önermişlerdir. Karşılaştırma aşamasında performans ölçütü olarak ise model sonuçlarının hata kareler ortalamalarını kullanmışlardır. İki modeli karşılaştırdıklarında, çok amaçlı karar verme modellerinin, tek amaçlı modellerden daha optimal sonuçlar verdiğini raporlamışlardır.

Su ve Cheng (2016), hisse senetleri fiyatlarının tahmin edilmesinin yatırımcılar ve bayilerin gündeminde olan bir durum olması sebebiyle hisse senedi fiyatlarının tahminlemesi üzerine çalışma gerçekleştirmişlerdir. Geçmişte yapılan benzer çalışmalarda zaman serisi yöntemleri kullanılmış olmasına rağmen Su ve Cheng zaman serisi yöntemlerinin hisse senedi fiyat tahmini için yetersiz olduğu görüşündedirler, bu nedenle çalışmalarında ANFIS (Adaptive Network-based Fuzzy Interference System) zaman serisi modelini kullanmayı önermişlerdir.

Alkan vd. (2019), Dünya ve Türkiye'deki benzetim tekniğinden yararlanarak Türkiye'deki 2002 ve 2018 yılları arasındaki değişim ve gelişimi anket yöntemi aracılığıyla ortaya koymuştur, elde edilen sonuçlar subjektif olarak değerlendirilmiştir.

Alkan vd. (2019) çalışmalarını beyin tümörü teşhisi için sınıflandırma yöntemlerinin başarımlarının karşılaştırması üzerine yapmışlardır. Naive Bayes' de %87 başarımlar, Lojistik regresyonda %90 başarımlar elde edilmiştir.

Literatürdeki tahminleme çalışmalarının büyük çoğunluğunda tahminleme yöntemi olarak yapay sinir ağı kullanılmıştır. Bunlardan ilki hava durumunun tahmin çalışmasıdır. Sonrasında Hu (1964), işletmeler üzerindeki yapay sinir ağları modeli çalışması ile model yaygınlaşmıştır. İşletmelerde yapay sinir ağları ile tahmini, öncelikle ekonomi ve finansta uygulanmış ve önemli sonuçlara ulaşılmıştır.

Agrawal ve Schorling (1996), pazar payı tahminlemesinde YSA'nın tahmin gücünü lojistik model ile kıyaslamışlardır. Çalışma sonucunda yapay sinir ağları ile kurulan modelin daha optimal sonuçlar verdiği ve yeteri kadar veri var ise yapay sinir ağlarının daha kullanışlı olduğunu belirtmişlerdir.

Wong vd. (1997), yapay sinir ağları temelli 1988-1995 seneleri arasındaki makalelerinde bir anket ile yapmış oldukları çalışmalarında yapay sinir ağları uygulamalarının her geçen gün artarak işletme faaliyetlerinde yer aldığını tespit etmişlerdir. Bunun sebebi olarak ise yapay sinir ağlarının her geçen gün gelişen ve değişen teknolojiye hızla uyum sağlayabiliyor olmalarını göstermişlerdir.

Hu (2002), iç turizm talebini ve Çuhadar vd. 2009'da, dış turizm talebini tahminlerken; yapay sinir ağları yönteminin diğer geleneksel metotlara göre daha yaklaşık tahminlerde bulunduğunu ortaya koymuşlardır.

Fildes vd. (2008), çalışmalarında herhangi bir bilgisayar tabanlı tahminlemenin sonuçlarının tahminleme ve planlama uzmanlarının eleştirel ve iyileştirici müdahaleleri ile hata oranının azalıp azalmadığını YSA ile tespit etmeye

çalışmışlar ve sonucun sektöre göre deđiřtiđi kanısına ulařmıřlardır. Çalıřmaya gre 2025'e kadar Amerika'da bu hizmete olan ihtiyacın artacađı sonucuna ulařılmıřtır.

Jones (2008), hastanelerin ilk yardım departmanlarındaki talep tahmini modellemesi çalıřmasında, gizli katmanlı, geri beslemeli yapay sinir ađı modeli oluřturmuřtur.

Asilkan (2009), ikinci el otomobillerin gelecek fiyatlarını yapay sinir ađları ile tahminlemiřtir. Arařtırmada, yapay sinir ađları ve zaman serisi analizleri ile elde edilen sonular karřılařtırılarak yorumlanmıřtır. Sonulara gre yapay sinir ađları sonularının daha bařarılı olduđu grlmřtr.

Avcı (2009) ise IMKB-30 endeksinde seilmiř birkaç hisse senedinin gnlk getirilerinin tahmini zerine yapay sinir ađı modeli tasarlamıř ve bařarılı sonulara ulařmıřlardır.

Sun vd. (2010), gemi turu endstrisinin, mřteri talep tahmini zerine yapay sinir ađı metodunu kullanarak çalıřmıřlardır.

İnsel vd., Hajirezaie vd. (2010), yapay sinir ađlarının planlama ve kalite kontrol uygulamalarının performansını belirlemede gvenilir ve hızlı olduđunu YSA ile sylemiřlerdir.

Aydođan vd. (2010), İstanbul bođazındaki deniz suyu akıntı hızının, Shamseldin (2010), Sudan'daki mavi Nil nehrinin akıř hızının tahmini zerine yapay sinir ađı modeli tasarlamıřlardır.

Erkaymaz ve Yaşar (2011), ileri beslemeli yapay sinir ağları ile Matlab'te geliştirdikleri model aracılığıyla hava sıcaklığını tahmin etmişlerdir.

Serttaş (2011), Türkiye içerisinde Perakende sektöründeki talebe etki eden faktörler ve yapay sinir ağları ile talep tahminlemesi konusunda çalışmıştır.

Buhari ve Adamu (2012), yapay sinir ağları metodu ile, Nijerya'nın elektrik yük tahminlemesini yapmışlardır.

Fan vd. (2012), yapay sinir ağlarını ile Avustralya için kısa vadeli elektrik yük tahminlemesi gerçekleştirmişlerdir.

Budak vd. (2012), bankaların kredi risklerini öngörmesine yardım etmek için, kredi talep eden müşterilerin ödeme periyodlarının tahminlemesi üzerine YSA ve lojistik regresyon kullanmışlardır. Çalışma sonucunda, YSA yönteminin müşterilerin ödeme alışkanlıklarının tahmin etme gücünün lojistik regresyon modelinden üstünlüğü görülmüştür.

Aygören vd. (2012), İMKB 100 endeksi ile ilişkili bazı piyasa değişkenlerini kullanarak YSA ile endeks tahmini yapmışlardır. Modelde İMKB 100, Faiz Oranı, Altın Fiyatları, Bankalar Arası Çift taraflı işlem miktarı TL ve USD günlük kapanış değerlerine ilişkin 3779 adet günlük veri kullanılmıştır ve sonuçta YSA'nın diğer yöntemlere göre tahmin üstünlüğü gözlemlenmiştir.

Şahin vd. (2013), çalışmalarında iç mekânlara ait aydınlatmaların tasarımı ve bu aydınlatmalar sonucu aydınlık seviyesinin belirlenmesi amacıyla yapay sinir ağlarının kullanımından söz etmişlerdir. Bu yönde aydınlık düzeyi tahmininde bir yapay sinir ağı modeli kurulmuş ve bu yönde eğitime tabii tutulmuştur.

Eđitilen yapay sinir ađı ile ortam ierisindeki her bir noktanın aydınlık dzeyi tahminlenmiř ve  boyutlu řekilde modellenmiřtir.

Moturi ve Kioko (2013), Kenya'nın kısa dnemlik elektrik yk tahminlemesini yapmıřlardır. Tahminlerinde yapay sinir ađlarını farklı iterasyonlarda kullanmıřlardır.

Utkun, E. (2014), alıřması kapsamında giyim sektrnde konfor neminin tahminlenmesinde yapay sinir ađları sistemlerinin kullanımını arařtırmıř ve alıřması sonucunda giyim konforunun tahmininde YSA kullanmanın bařarılı sonular getirdiđi grlmřtir.

Var ve Trkay (2014), yapay sinir ađları yntemi ile İstanbul'daki bir blgenin elektrik puant ykn tahminlemiřlerdir. Bu makalelere rnek olarak alıřma yapay sinir ađları ile uygulamaya dklmřtir.

řentrk vd. (2016), gđs kanserinin erken tanısına katkı amacıyla bilgileri veri tabanında mevcut olan vakaların verilerini kullanarak, henz teřhisi belli olmayan rneklere tahminleme yoluyla teřhis koymak zerine alıřmıřlardır. Tahmin, dođruluk oranı tasarlanan bir yapay ađa denendiđinde %77 olarak bulunmuřtur.

Kıyıldı (2017), alıřmasında YSA tekniđi ile Trkiye iin kaza tahmin modeli zerinde durmuřtur. alıřması sonucunda eřitli senaryoları izleyerek kaza, yaralı ve l sayıları tahminlerinin YSA ile bařarılı řekilde yapılabileceđi sonucunu ortaya koymuřtur.

Gürgen vd. (2017), yapmış oldukları çalışmalarında bir Diesel motorunda motor performansı ve egzoz emisyonları YSA ile modellemişlerdir. Geliştirilen modelin, deneysel sonuçlara uygun olduğu görülmüştür.

Kırbaş (2018), çalışmasında rüzgâr hızı verilerini istatistiksel ve YSA metotları ile incelemiş ve zaman serisi üzerinden geleceğe yönelik rüzgâr hızı tahminlerinde bulunmuştur. Çalışma sonucunda incelenen ARIMA modelleri ve YSA arasında belirgin bir hata oranı farkı görülmüştür.

Çam vd. (2018), Türkiye'nin enerji verimliliğini ARDL yöntemi, TOPSIS yöntemi ve YSA analizleri çerçevesinde 1960- 2013 dönemi için incelemişlerdir. Çalışma sonucunda Türkiye'nin enerji verimliliğinin yıllara göre arttığı görülmüştür.

Şahin (2018), araştırmasında, bitcoin fiyat tahmini yaparak sonuçları son yıllarda tahmin yöntemleri arasında giderek daha popüler hale gelen YSA ve geleneksel tahmin yöntemlerinden ARIMA ile karşılaştırmıştır. Bu çalışma sonucunda YSA değerleri, ARIMA modelinden daha başarılı olmuştur.

Yazıcı (2018), çalışmasında diskriminant analizi, yapay sinir ağı ve lojistik regresyon yöntemlerini bir uygulamada karşılaştırmıştır. Çalışması sonunda iyi ve kötü kredi ayırımının yapay sinir ağı metodu ile daha başarılı şekilde yapıldığı gözlemlenmiştir.

Calp (2019), çalışmasında işletmeler için YSA kullanılarak günlük yemek talebini tahminleyen yapay zekâ tabanlı bir model önermiştir. Çalışma sonunda, modelin hata oranının düşük olması ile talep tahmini için YSA'nın kullanılabilirliği ortaya konmuştur.

Koçak vd. (2019), çalışmalarında WLAN'larda YSA kullanılarak veri trafiğine ait uygun değerleri elde etmişlerdir. Bu değerlere göre, geliştirilmiş YSA modelinin ezberlemediğini, girdi ve çıktılar arasında ilişki kurabileceği görülmüştür.

Talep tahminine ait literatür örnekleri aşağıdaki Çizelge 2.1.'de özetlenmektedir:

YIL	YAZAR	YÖNTEM	TAHMİN
1964	Hu	Yapay Sinir Ağı	Hava Durumu Tahmini
1980	Carlson ve Umble	Otomobil Talep Tahmini	Regresyon Analizi
1995	Kauffman ve Sopariwala	Tahmin Modelleri	Pazar Büyüklüğü Değişkenleri Tahmini
1996	Agrawal ve Schorling	Yapay Sinir Ağı	YSA ve Lojistik Model Kıyaslaması
1997	Wong vd.	Yapay Sinir Ağı	İşletmelerde YSA Kullanımı
1999	Gavcar vd.	Türkiye'deki Kağıt-Karton Türlerinin Talep Tahminleri	Regresyon Analizi
2002	ZhoumcMahon vd.	Melbourne Şehri'nin Su Talp Tahmini	Zaman Serileri Analizi
2002	Hu	Yapay Sinir Ağı	İç Turizm Talep Tahmini
2004	Cahow	Kronik Hastaların Hemşire Talebi	Çoklu Regresyon Analizi ve Monte Carlo Simulasyonu
2009	Matuyama vd.	Kesikli Envanter Tahmini	Regresyon ve Zaman Serileri
2008	Fildes vd.	Yapay Sinir Ağı	Bilgisayar Tabanlı Tahminleme İhtiyacı

2008	Jones	Yapay Sinir Ağı	Hastanelerin İlk Yardım Departmanlarındaki Talep Tahmini
2009	Çuhadar vd.	Yapay Sinir Ağı	Dış Turizm Talep Tahmini
2009	Asilkan	Yapay Sinir Ağı	ikinci El Otomobillerin Gelecek Fiyatları Tahmini
2009	Avcı	Yapay Sinir Ağı	Hisse Senetlerinin Günlük Getirisi Tahmini
2010	Griffiths vd.	Regresyon Analizi	Yerel Buğday Verimliliği Tahmini
2010	Sun vd.	Yapay Sinir Ağı	Gemilerde Yapılan Tur Endüstrisinin Müşteri Talep Tahmini
2010	Aydoğan vd.	Yapay Sinir Ağı	İstanbul Boğazına Ait Deniz Suyunun Akıntı Hızı Tahmini
2010	Shamseldin	Yapay Sinir Ağı	Mavi Nil Nehri'nin Akış Hızının Tahmini
2011	Erkaymaz ve Yaşar	Yapay Sinir Ağı	Hava Sıcaklığı Tahmini
2011	Serttaş	Yapay Sinir Ağı	Türkiye'de Perakende Sektöründe Talep Tahmini
2012	Buhari ve Adamu	Yapay Sinir Ağı	Nijerya'nın elektrik yük tahminlemesi
2012	Fan vd.	Yapay Sinir Ağı	Avustralya için kısa dönemli elektrik yük tahminlemesi
2012	Budak vd.	Yapay Sinir Ağı	Kredi Riski Tahmini



2012	Aygören vd.	Yapay Sinir Ağı	IMKB 100 Endeksi Tahmini
2013	Wei	ANFIS - Zaman Serisi Modeli ve Genetik Algoritma	Hisse Senedi Fiyat Tahmini
2013	Moturi ve Kioko	Yapay Sinir Ağı	Kenya için kısa dönemli elektrik yük tahminlemesi
2013	Şahin vd.	Yapay Sinir Ağı	Çalışma Ortamlarındaki Aydınlik Şiddeti Tahmini
2014	Babic vd.	Havayollarına Ait Pazar Payı Tahminlemesi	Regresyon ve Bulanık Mantık
2014	Var ve Türkay	Yapay Sinir Ağı	İstanbul'da Bir Bölgenin Elektrik Puant Yüğü Tahmini
2014	Emine Utkun	Yapay Sinir Ağı	Giyim Konforu Tahmini
2015	Majhi ve Anish	Borsa Tahminlemesi	Çok Amaçlı Parçacık Sürüş Optimizasyonu ve Genetik Algoritma
2016	Su ve Cheng	ANFIS - Zaman Serisi Modeli	Hisse Senedi Fiyat Tahmini
2016	Şentürk vd.	Yapay Sinir Ağı	Göğüs Kanseri Tahmini
2017	R.Koray Kıyıldı	Yapay Sinir Ağı	Trafik Kazası Tahmini
2017	Gürgen vd.	Yapay Sinir Ağı	Motor Performansı ve Egzoz Emisyonlarının YSA ile tahmini
2018	İsmail Kırbaş	Yapay Sinir Ağı	Rüzgar Hızı Tahmini
2018	Ayüp Ensari Şahin	Yapay Sinir Ağı ve ARIMA	Bitcoin Fiyat Tahmini

2018	Çam vd.	Yapay Sinir Ağı ve ARIMA	Türkiye'nin Enerji Verimliliğinin Tahmini
2018	Mehmet Yazıcı	Diskriminant Analizi, Yapay Sinir Ağları ve Lojistik Regresyon	Kobiler için Mali Başarısızlık Tahmini
2019	M. Hanefi CALP	Yapay Sinir Ağı	Personel Yemek Talep Miktarı Tahminlemesi
2019	Koçak vd.	Yapay Sinir Ağı	Kablosuz Yerel Alan Ağlarında Veri Trafiği Optimizasyonu
2019	Alkan vd.	Benzetim Modeli	Türkiye için bir benzetim değerlendirmesi
2019	Alkan vd.	Lojistik Regresyon, Naive Bayes	Beyin Tümörü Teşhisi Tahmini
2019	Türk vd.	Yapay Sinir Ağı	Beyaz Eşya Üretim Planlaması Tahmini

Çizelge 2.1. Talep Tahmini ile İlgili Örnek Modeller

Literatürde de görüldüğü üzere Yapay sinir ağları, büyük farkla son yıllarda oldukça fazla gelişim gösteren bir çalışma yöntemidir ve geleceği tahmin etmede kullanılan tahminleme yöntemlerine alternatif olarak geliştirilmiştir.

Tahminleme yöntemleri, ana olarak nicel ve nitel şeklinde iki başlıkta incelenmektedir. Çoğunlukla nicel yaklaşımlardaki girdi verileri, zaman aralıklı olarak toplanan veriler olurken nitel yöntemler subjektif girdiler ile ilerlemektedir. Verilerin sağlıklı analizi, bu yöntemlerin en önemli özelliğidir.

Yapay sinir ađlarında ise literatüre ait ilk alıřmalar beyin hücrelerinin haberleşme şekillerinin belirlenmesini istenmekteydi. İlgili dönemden beri Yapay Sinir Ađları hem teorik hem pratik anlamda önemli ilerleme kaydetmiştir. Bugün birçok nöronun birlikteliđi ile ve optimum öğrenme algoritmaları ile yapay sinir ađları kurulabilmekte ve oldukça karışık görevleri başarıyla gerçekleştirebilmektedir. Ađ, girdi olarak sunulan veriler ile bağlantı kurarak, problemi öğrenerek, deneysel sonuçları depolamakta ve kullanıma hazır hale getirmektedir.

Literatürde yapay sinir ađlarının genellikle çok girdi ve ıktıdan oluşan yapısı ile tahminleme yapılırken; zaman serisi olarak kullanıldığı alıřmalara sık rastlanmamıştır. Yapay sinir ađlarında hesaplama, algoritmik programlamaya alternatif olabilecek bir bilgi şekillendirme mekanizmasıdır. Ancak yapay sinir ađları önceki hesaplama seçeneklerinden farklı bir hesaplamayı yöntem olarak sunmaktadır. Yer aldıkları duruma uyum sađlayan, tam olmayan bilgi ile ilerleyebilen, belirsizliklere rağmen karar verebilen, hata toleranslı olan yapay sinir ađlarının yaşamın hemen hemen her alanında oldukça başarılı uygulamalarına rastlamak mümkündür. Kurulacak ađın yapısının seçilmesi, ađ parametrelerinin belirlenmesi, problemlerin sadece sayılar ile belirtilebilmesi, eğitimin nerede biteceđinin tahmin edilemiyor olması ve ađın açıklanamayan davranışlarına rağmen yapay sinir ađlarına olan ilgi her geçen gün çođalmakta ve dikkat çekmektedir. Özellikle tahmin, örüntü tanıma, sinyal filtreleme, sınıflandırma ve optimizasyon alıřmalarında yapay sinir ađları en çok kullanılan yöntemler arasında sayılabilir. Yapay sinir ađları, doğrusal olmayan ve paralel işleme ile, ortam deđişikliğinde sonucu deđiştirebilme, girdilerdeki ufak deđişimleri tolere edebilme, deđişik veriler karşısında deneyimi olmamasına rağmen yeni verileri cevaplayabilme gibi üstün yeteneklere sahiptir. Yapay Sinir Ađlarının mevcut olan bu avantajlarından yola ıkarak hazırlanan alıřmamızda YSA modellerinin daha düşük hatalar vermesinden dolayı daha başarılı olduđu görülmüştür.

Ülkemizde hem Yapay Sinir Ağları ile hem de geleneksel şekilde süre gelen zaman serileri tahmin yöntemleri ile satış modellerinin belirlenmesi ve tahminlenmesine ilişkin çalışmaların sınırlı olduğu ve çalışma için verileri kullanılan Türkiye'nin öncü perakende şirketinde mevcut olan herhangi bir satış tahminleme yönteminin kullanılmadığı dikkate alındığında, bu çalışmanın Türkiye'de yapılmış olan satış tahminleme literatürüne ve buradaki yöneticilerin geleceğe ait planlama çalışmalarına önemli katkılar sunacağı hedeflenmektedir.

Her geçen gün gelişmeye devam eden yapay sinir ağları gelecekte, sistemlerin kalitesinin artırılmasına yönelik de önemli yarar sağlayacaktır.

### 3. TALEP TAHMİNİ VE TAHMİN YÖNTEMLERİ

#### 3.1. Talep Tahmini Kavramı

Talep, tüketicinin belli bir ürün ya da hizmeti belirlenen bir fiyat karşılığında alabileceği miktardır (Tekin, 1996). Talep tahmini ise, gelecek bir dönemde bir kişi ya da şirketin satın alacağı bir ürünün veya ürünlerin satın alınacağı miktarını tahmin etmektir (Acar, 1989). Talebin eş olarak satış anlamına gelmesi sebebiyle “talep tahmini” yerine “satış tahmini” de denilebilir.

Talep tahmini, bir şirketin kısa ve uzun dönemli hedeflerine yönelik yönetim kararlarının alınmasında başvurulan en etkili araçtır. Talebin tahmini için doğru yöntemin seçilmesiyle optimum karlılık yakalanarak şirketin stratejik hedefleri ile operasyon ihtiyaçları arasındaki çelişkiler azaltılır (Bolt, 1981).

Talep tahmini belirli yöntemler ile yapılır ancak kullanılan yöntem ne olursa olsun tahmin %100 doğruluk derecesinde değildir. Talep tahmini yapılacak ürünün özellikleri, talep tahmin yöntemini ve süresini etkiler. Ürünün talebi dönemsel olarak değişmiyorsa bu süre daha kısa, dönemsel olarak değişken bir talep söz konusu ise bu süre daha uzundur (Acar, 1989).

Talep tahmini genel olarak dört döneme göre ele alınır (Tekin, 1996):

- Çok kısa zamanlı tahminler: Tahminin günlük ve/veya haftalık yapılmasıdır. Stok kontrolü, sipariş verme gibi amaçlar ile kullanılabilirler.
- Kısa zamanlı tahminler: 1 hafta ile 6 ay aralığında olan tahminlerdir. Optimum siparişi tutarını belirleme, makine ve iş gücü tahmini gibi amaçlar ile kullanılırlar.

- Orta zamanlı tahminler : 6 ay ve 5 yıl aralığında yapılan tahminlerdir. Uzun tedarik zamanı gerektiren malzeme alımlarında planlama amaçlı kullanılırlar.
- Uzun zamanlı tahminler: 5 yıl ve üzeri zamanlı yapılan tahminlerdir. Yatırım kararlarında, sermaye planlamasında kullanılırlar.

Talep tahmini yapılırken belirli kurallar dikkate alınmalıdır (Acar, 1989):

- Talep tahmini yapılacak grup miktar veya çeşit olarak büyüdükçe tahmin doğruluğu artar,
- Yakın zaman tahminleri daha doğru sonuç verir,
- Tüm talep tahminlerinde belirli bir hata oranı olmalıdır,
- Talep tahmini araştırmasını kullanmadan önce seçilen yöntem test edilmelidir.

### **3.2. Talep Tahmin Adımları**

Talep tahmini 5 adım ile özetlenebilir:

1.Talebi Nelerin Etkilediğinin Seçilmesi: Talep tahmini öncesinde şirket çevresi, üretilen ürün, şirketin güncel ve gelecekteki olmak istediği durumu, rakipleri, piyasa, teknoloji, endüstriyel gelişimler, sosyal durum gibi talebi etkileyen etmenler ve ağırlıkları belirlenmelidir (Bolt, 1994).

2.Verilerin Elde Edilmesi: Talebi etkileyen faktörler dikkate alınarak planlama için gerekli veriler toplanır (Bolt, 1994).

3. Talebi Tahmin Etme Periyodunun Belirlenmesi: Talep tahmini kısa ya da uzun dönemli olarak nasıl bir periyod için kullanılacak tahmin öncesinde belirlenmelidir (Tekin, 1996).

4. Tahminleme Metodunun Seçilmesi: Tahmin yöntemi nesnel ya da öznel olabilir. Bu aşamada kullanılacak yöntem seçilmelidir (Bolt, 1994).

5. Tahminlemeye Ait Sonuçların Doğruluğunun ve Geçerliliğinin Değerlendirilmesi: Tahmin ve gerçek karşılaştırılarak belirli bir hata oranı belirlenmelidir.

### **3.3. Talep Tahmin Yöntemleri**

İstatistiksel yöntemler, talebi etkileyen faktörleri dikkate alarak geçmiş talep verilerinden hareket ile güncel girdileri analiz ederek talebi tahmin etmeyi sağlamaktadır. Talep tahmin yöntemleri temelde nitel, nicel ve yapay zeka tabanlı yöntemler olarak üç sınıfta değerlendirilebilir. Nitel yöntemler genellikle uzman kişilerin görüşleri ile bağlantılıyken, nicel yöntemler matematiksel ve istatistiksel hesaplamaları temel alır. Bu yöntemler ile sonuç alınmadığında ise yapay zeka tabanlı yöntemlere başvurulur.

#### **3.3.1. Nitel yöntemler**

Bu yöntemde veriler nicel olarak değerlendirilmez ve sezgiseldir. Sezgisel olması ve bilimsel veriler içermemesi sebebiyle tahmin performansı diğerlerine göre düşüktür.

### **3.3.1.1. Uzman görüşünün alınması**

Tahmini yapılacak konuda uzmanlığı olan kişinin deneyim, bilgi ve sezgilerine bağlı olan tahmindir. Kısa dönemlik alınan kararlar için bu yöntem kullanılabilir ancak tamamen kişisel yargılara dayandığı için yanlış sonuç verme olasılığı yüksektir.

### **3.3.1.2. Delphi tekniği**

Bu teknik, genellikle subjektif durumlarda karar verirken veya kararlar güçlü gruplar tarafından etkilenecek ise kullanılır.

Bu teknikte tahmin yapacak kişilere genel olarak ardışık anketler uygulanır. Teknik 3 temel özelliği vardır:

1. Katılımın Gizli Yapılması
2. Grup Tepkisinin Ne Olacağına İstatistiksel Analizi
3. Kontrollü Yapılan Geri Beslemeler

### **3.3.1.3. Anket metodu**

Hedef kitleye, talep tahmini için anket uygulanmasıdır ancak güvenilirliği araştırmacıya çeşitli yönlerden dezavantaj sağlayabilmektedir.



### 3.3.2. Nicel yöntemler

Nicel yöntemler geçmişe ait fiilen gerçekleşen talep değerlerine dayalı istatistiksel yöntemlerdir. Talebe etki eden faktörler ve talep arasındaki ilişkinin gelecekte aynı eğilimi göstereceği düşüncesine dayanır. İstatistiksel metotlar ile geçmiş veriler incelenir ve buradan hareket ile gelecek tahmin edilir.

Nicel yöntemlerin dayandırıldığı zaman serisi ve nedensel yöntemler, geçmişe ait verilerden hareket ile, gelecek talebe belirli bir eğilim olup olmadığının incelenerek, gelecek tahminin yapılmasıdır. Zaman sırasına dizilen geçmiş veriler incelenir. Bu geçmiş dönem verilerini temsil eden model kurularak tahmin yapılır.

Zaman serilerini başlıca 5 faktör etkiler. Bunlar; mevsimsel değişim, eğilim, periyodik değişim, ortalama ve rastgele durumlardır (Arbib, 2003).

1. Ortalama: Geçmiş datalar, ortalama bir değerde tekrar eder.
2. Mevsimlik değişim: Mevsimsel talebin değişmesi durumudur.
3. Eğilim (trend) : Verilerin sürekli olarak aynı eğilimde değişmesidir.
4. Konjonktürel Değişim: Geçmiş verilerin, mevsimsel değil de daha uzun zaman aralıklarında değişmesidir.
5. Rastgele Durumlar: Genelde düzenli olmayan ve önceden tahmin edilmesi güç olaylardır. Örnek olarak; deprem sebebiyle yıkılan konutlar sonrasında konut talebinde artış meydana gelmesi.

Zaman serileri ve nedensel yöntem analizinde regresyon analizi, korelasyon analizi, basit ve hareketli ortalamalar metodu, Simülasyon (benzetim) gibi yöntemler uygulanmaktadır (Tekin, 2009). Bu geleneksel talep tahmin yöntemlerini temelinde barındıran yapay sinir ağları da günümüzde yaygın kullanılmaya başlanan önemli bir talep tahmin yöntemidir.

Sonraki bölümlerde tezde uygulaması yapılacak olan yapay sinir ağları yöntemi ile talep tahmini ayrıntılandırılarak anlatılacaktır.

### 3.3.4. Tahmin yöntemlerinin karşılaştırılması

Tahmin yöntemlerin özelliklerinin bulunduğu, güçlü ve zayıf yanlarının kıyaslandığı özellikler Çizelge 3.1'de yer almaktadır.

	NİTEL YÖNTEMLER	NİCEL YÖNTEMLER
ÖZELLİĞİ	Subjektiftir Kişisel görüş ve deneyimlere dayanır	Matematikseldir
GÜÇLÜ YANI	Değişen koşullar ile modele yansıtılabilir	Objektif ve tutarlıdır Birçok veri ve bilgiyi tek seferde göz önünde bulundurur
ZAYIF YANI	Önyargılı tahmin sonucu elde edilebilir, kişisel yargıları içerdiğinden tahmin doğruluğu düşük olabilir	Her zaman ölçülebilir veri bulunamayabilir, sonuçların doğruluğu kullanılan veriye bağlıdır

Çizelge 3.1 : Tahmin Yöntemlerin Karşılaştırılması (Pirim,2006)

Nitel ve nicel yöntemlerin yanında, literatürde geleceği tahmin etme amacıyla yapay sinir ağları (YSA), genetik algoritma (GA) ve bulanık mantık (BM) tahmin yöntemleri de kullanılmaktadır.

### 3.3.5. Tahmin yöntemlerinin doğruluğunun ölçülmesi

Kurulan tahmin modellerinin öngörülerindeki başarıları karşılaştırmak için çeşitli kriterler mevcuttur. Bu tahmin ile gerçekleşen değerler arasındaki farktan meydana gelen tahmin hatasının analiz edilmesiyle ölçülür.

Rastgele bir periyoda ait tahmin hatası aşağıdaki (1) numaralı denklem ile ölçülür:

$$e(t) = Y(t) - F(t) \quad (1)$$

$Y(t)$ ; gözlenen gerçek değer,  $F(t)$  modelin ürettiği değerdir.  $e(t)$  değeri ise tahmin hatasını temsil eder.

En yaygın kullanılan tahmin doğruluğu ölçüm kriterleri:

1. Ortalama hata kareleri ( Mean Squared Error- MSE): Hata karelerine ait ortalama, talep tahminlerinin doğruluğunun tespitinde yaygın kullanılmaktadır. Bu yöntem hataları işaretlerden temizler ve yalnızca büyüklükleri ile ilgilenir. Gerçekleşen değerler ve tahmini değerlerin arasındaki farkın karelerinin ortalama toplamıdır.
2. Kök ortalama hata kare ( Root Mean Squared Error – RMSE): Ortalama hata kareleri metoduyla tespit edilen hatanın karekökü ile bulunur.
3. Ortalama mutlak yüzde hata (Mean Percentage Absolute Error- MAPE): Burada hatalar yüzdesel ifade edilir. Böylece hataların birbirleri ile karşılaştırılabilmesi sağlanır.

## 4. YAPAY SİNİR AĞLARI

### 4.1. Tanım

Biyolojik sinir ağı, insanların çevresini anlamasını ve davranışları anlamlandırabilmesini sağlar. Bir sinir ağı, milyarlarca sinir hücresinden meydana gelir ve yapısı akson, sinapslar, hücre gövdesi ve dendritlerden oluşur. Sinapslar, sinir hücrelerinin birbirleri arasında elektrik sinyallerinin aktarılmasını sağlayan bağlantılardır. Bu sinyaller sonraki adımda somaya ve dendritlere iletilerek bir sonraki sinaps ile diğer sinir hücrelere iletilir.

Yapay sinir ağı, insan beyninin çalışma mekanizmasına paralel olarak beynin öğrenme, öğrendiğini anımsayabilme, önceki bilgilerinden yola çıkarak yeni bilgiler üretebilme gibi temel fonksiyonlarını yerine getirmek üzere geliştirilen mantığa dayalı yazılımlardır. Çalışma mekanizması olarak biyolojik sinir ağını taklit ederler (Aladag, C. H., Basaran, M. A., Egrioglu E., Yolcu, U., Uslu V. R., 2009).

Yapay sinir ağı, beynin bir fonksiyonu gerçekleştirme özelliğini modellemek için uyarlanan bir sistem olarak tanımlanabilir. Yapay sinir ağı, yapay sinir hücrelerinin birbirlerine bağlanmasıyla meydana gelir ve genel olarak katmanlar şeklinde düzenlenir. Beynin bilgi işleme özelliğine uygun olarak yapay sinir ağı, belli bir öğrenme zamanından sonra bilgiyi genelleme ve saklama yetisine sahiptir (Ergezer vd, 2003).

Yapay Sinir Ağları, basit bir biyolojik sinir sisteminin çalışma algoritmasını taklit amacıyla tasarlanmış programlardır (Yurtoğlu, 2005). Taklit edilen sinir hücreleri nöronlar içerirler ve bu nöronlar birbirlerine bağlanarak ağı oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki bağlantıyı ortaya çıkarma kapasitesine sahiptirler.

## 4.2. Tarihsel Gelişim

Yapay sinir ağlarının temeli W.S. McCulloch ve W.A. Pitts'in, 1943 yılında yayınladıkları bir makaleyle atılmıştır. Ardından 1954'te B.G. Farley ve W.A. Clark tarafından daha gelişmiş başka bir model oluşturulmuştur. 1960 ise tam anlamıyla neural bilgisayarın ortaya çıkış yılı olarak sayılmaktadır.

1963'te basit modellerin eksik yanları fark edilmiş, fakat başarılı sonuçlar 1970 ve 1980 yıllarına kadar gecikmiştir. 1985 yılı ise yapay sinir ağlarının iyice tanındığı, güçlü araştırmaların başladığı yıl olmuştur (Pankaj, M., Benjamin, W. 1992).

### 4.2.1.Yapay sinir ağlarının kullanım alanları

1980'li yıllara ait gelişmeler sayesinde yapay sinir ağlarının sonuçlanamaya sorunlarının çözülmesi ve doğrusal olmayan verilere adaptasyonunun gösterilmesinden sonra ağlar; ekonomi, tıp ve mühendislik alanları gibi birçok alanda uygulanma fırsatı bulmuş ve oldukça verimli sonuçlar ortaya çıkarmıştır (Müller ve Reinhardt, 1990).

Yapay sinir ağları uygulamaları ağın yerine getirdiği görev bakımından özetle aşağıdaki gibi gruplandırılabilir (Fuente, 2004):

- Birleştirme
- Gruplandırma
- Sınıflara Ayırma
- Şablonları Tanıyabilme
- Regresyon Yapma ve Genelleyebilme
- Optimizasyon

Yapay sinir ağı kullanımı ile ilgili genel düşünce yapay sinir ağlarının bugün herhangi bir yöntemle çalıştırılan herhangi bir fonksiyonu çalıştırabileceği ve geleneksel modelleme yöntemlerine göre daha etkin çözümler üretebileceği yönündedir (Şahin, 2002). Bu konuda yapılan bir araştırmada ele alınan 42 çalışmanın 30'unda (%71) yapay sinir ağlarının geleneksel istatistik tekniklerine oranla daha iyi çıktılar ürettiği görülmüştür (Şahin, 2002).

Çizelge 4.1'de geleneksel algoritmalar ile YSA'ların karşılaştırması görülmektedir:

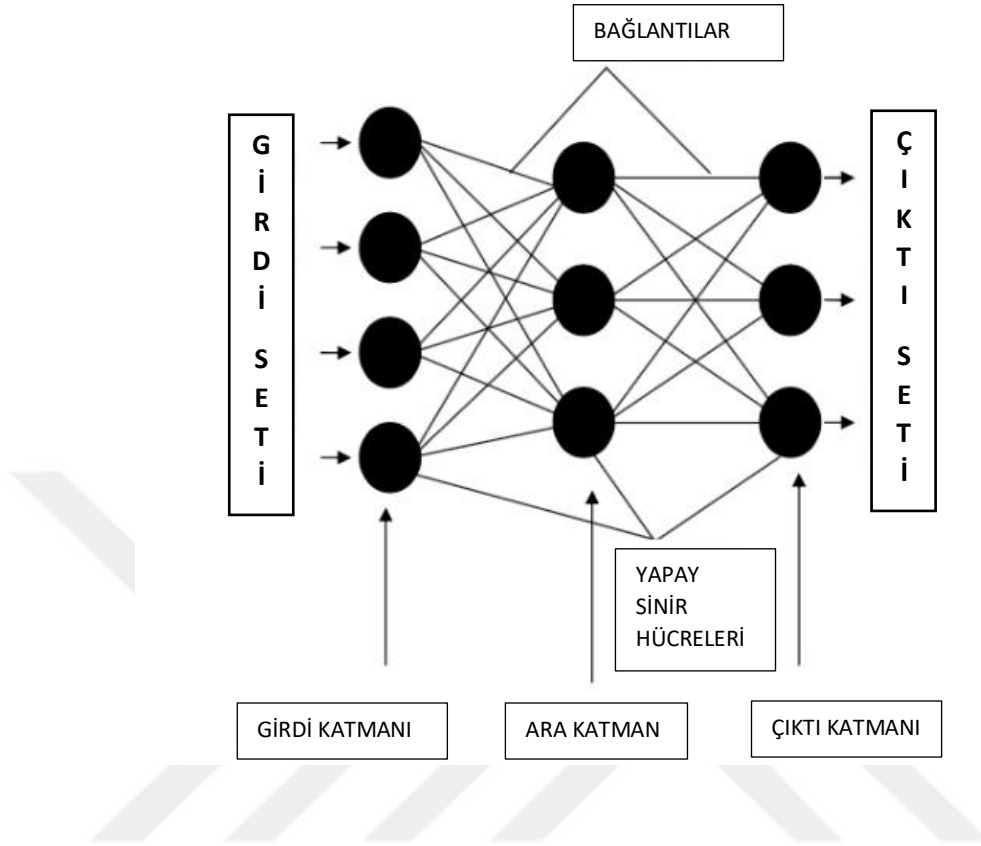
Geleneksel Algoritmalar	Yapay Sinir Ağları
Çıkış değerleri, belirlenen kurallara giriş verilerinin sunulmasıyla elde edilir.	Öğrenme sırasında giriş ve çıkış bilgileri verilerek kurallar tespit edilir.
Bilgiler kesindir.	Deneyimlerden faydalanma vardır.
Hesaplama; eşzamanlı ve ard ardadır.	Hesaplama; öğrenmeden sonra paraleldir.
Hazır bilgi bellekte depolanmaktadır.	Bellek ayrılmış şekilde ve dağınıktır.
Hata toleransı yoktur.	Hata toleransı vardır.
Kıyasla daha hızlıdır.	Yavaş ve donanım bağımlıdır.

Çizelge 4.1. Geleneksel Algoritma ile YSA Kıyası (Pirim,2006)

### 4.3. Yapay Sinir Ağları Yapısı

Yapay sinir ağları farklı katmanlarda toplanmış hücreler ve bu hücrelere ait bağlantılardan oluşur (Arbib, 2003). Katmanlar ise bağlantılı olan sinir hücresi kümeleridir (Tebo, 1994).

Yapay sinir ağlarının yapısı aşağıdaki şekil 4.1.'de gösterilmektedir:



Şekil 4.1. Yapay Sinir Ağı Yapısı (Freeman ve Skapura, 1991)

Yapay sinir ağının büyüklüğü özetle iki ana kriter ile ifade edilir:

- Ağa ait katman sayısı ve
- Gizli birim adeti (Fuente, 2004).
- Girdi katmanı, başlangıç verilerinin ağa tanıtıldığı yerdir. Bu katmandaki sinir hücreleri, problemin girdi parametrelerinin sayısına eşittir ve her sinir hücresi ilgili girdiye ait verileri içerir (Veelenturf, 1995). Bu hücrelerde işlem yapılmaz (Şahin, 2002).
- Gizli katman, yapay sinir ağının işlem gördüğü katmandır. Bu katman kullanıcı tarafından görülmez ve girdi katmanından ağa sunulan datanın

çalıřılan probleme uygun bir fonksiyonla iřlendiđi ve sonu elde etmek amacıyla ıktı katmanına iletildiđi katmandır. Bir ađın yapısında ka adet gizli katman bulunacađı probleme gre deđiřkenlik gstermektedir

- ıkıř katmanı ise, girdi katmanı aracılıđıyla ađa sunulan ve gizli katmanda iřlenmiř verilerin ađın yapısına uyacak bir fonksiyonla iřlem grdđi ve sonucun ıktı olarak sunulduđu katmandır. Ađın ıktı sayısı, ađdaki ıkıř katman sayısına eřittir.

#### **4.4. Yapay Sinir Ađlarının Genel zellikleri**

Yapay sinir ađları zmlerin algoritmik bir Őekilde formle edilemediđi, rnek davranıřın birok haline eriřilebildiđi, mevcut veriler ile bu verilerin bulunduđu yapının tanımlanması gereken problemlerde kullanılabilir ve yararlanılabilir donanım ve/veya yazılımda oluřabilecek sorunlara karřı dayanıklıdırlar (Smith, 2003).

##### **4.4.1. Paralellik zelliđi**

Yapay sinir ađları bađımsız ancak eř zamanlı olacak Őekilde alıřan elemanlardan oluřur. Bařka bir deyiř ile ađın yapısında bir sinir hcresi yalnızca kendisi ile ilgili olacak blm iřler. Bu yapı ierisinde btn ađa ait gerekleřtirilmesi beklenen iřlev paralel olarak hcrelere yklenmiřtir (Haykin, 1994). Bu zellik ađa hız ve dayanıklılık avantajı sađlamaktadır.

##### **4.4.2. đrenme, genelleme ve uyum sađlama zellikleri**

Yapay sinir ađları eđitim srecinde iřledikleri verileri đrenerek genelleme yapabilme ve daha nce rastlamadıkları problemleri de bu ıktılardan hareketle zebilme zelliklerine sahiptirler. Buna da ek olarak, mevcut problemde



değişiklik gösteren durumlar söz konusu olduğunda da ağ yeniden eğitilerek ağın yeni duruma uyumu sağlanabilmektedir (Grossberg, 1992).

#### **4.4.3.Yüksek hata toleransı**

Yapay sinir ağları bulanık (hatalı ya da eksik) girdilerin bulunduğu problemlerde bile çıktı verileri arasındaki ilişkiler ile ilgili yaklaşım kurabilir ve mantıklı çıktılar sunabilirler (Smith, 2003).

#### **4.4.4. Yapay sinir ağlarının dezavantajları**

Bahsedilen avantajların yanında yapay sinir ağlarının avantajları yanında birtakım dezavantajları da vardır.

Bunlardan ilki; eğitilme sürecinin uzun ve karmaşık olmasıdır. Ağın başarısı bu eğitim süreci ile doğrudan ilişkilidir. İkincisi ise detaylı programlanan yapılar olmadıkları için üretilen çözümlerin nasıl ve neden üretildikleri konusunda açıklama yapılamamakta ve kapalı kutu olarak nitelendirilebilmektedirler (Dereli, 2000).

#### **4.5.Yapay Sinir Ağlarında Öğrenme**

Yapay sinir ağları örnekler üzerinde çalışarak çözümü öğrenen yapılardır. Sonraki süreçte ise bunlardan yola çıkarak daha önce karşılaşmadıkları problemler için benzer şekilde çözüm üretebilirler (Murray, 2003).

Bu öğrenme süreci iki maddede incelenebilir (Tebo, 1994):

- Yapay sinir ağının problemlerin geçmiş verileriyle çalıştırılması ve çözüm yaklaşımı oluşturması (öğrenme aşaması),
- Eğitim sonrası yapay sinir ağı çıktılarının doğruluğunun değerlendirilmesi ve tutarlılık testi (test aşaması)

Yapay sinir ağlarında öğrenme, sinir hücreleri arasındaki bağlantı güçlerini, probleme en çok uyacak çözümleri üretecek kombinasyona taşımasıdır (Barghash ve Santarisi, 2004). Yapay sinir ağının tasarlanmasının ardından, problem kapsamında ağın eğitilmesi ve test edilmesi için problemin geçmişe ait verileri ile birbirinden farklı olacak şekilde iki grup oluşturulur. Eğitim ve test grupları olarak 2 grup oluşturulmalıdır çünkü eğitim esnasında probleme adaptasyonu sağlanmaya çalışılan yapay sinir ağı modelini, o zamana kadar hiç karşılaşmamış olduğu koşullarla sınamak ve genelleme yapmak önceliklidir.

Yapay sinir ağının kurulduğu ilk anda sinir hücrelerini birbirine bağlayan bağlantılara rassal kuvvetler atanır. Model, çalıştırıldığında ise veri kümelerine ait sonuçlarla ilgili tahminlemeler gerçekleştirilir. İlerleyen süreçte ağ bağlantı kuvvetlerini adım adım iyileştirir ve eğitim, modelin çıktılarının tutarlı olduğunun anlaşıldığı ve kararlı bir durum aldığı ana kadar sürdürülür.

Kararlı hale geçen ve bu halinden emin olunan sistemin eğitimi sona ermiş demektir ve bu aşamadan sonra test aşamasına geçilir. Daha önce eğitilmiş olan ağa daha önce rastlamamış olduğu veriler sunulur ve bu veriler ile çalışması sağlanır. Sonuç ürettikten sonra ise bu sonuçların performansı ölçülür Literatür incelendiğinde yapay sinir ağlarının çıktı sonuçlarına ait performansı ölçmede birçok yöntem kullanıldığı görülmektedir. Bu yöntemlere örnekle; ortalama akış

süresi, hedef oranı, ortalama hedef model akış süresi ve hata karelerinin toplamı verilebilir (Barghash ve Santarisi, 2004).

Bağlantı güçlerinin birbirine adapte olması şeklinde ilerleyen ağın eğitimi için günümüze dek geliştirilmiş birçok algoritma vardır. Güncel algoritmalar ağın eğitilmesi esnasında kullanılan veri kümelerinin yapısına göre üç ana başlıkta özetlenebilir:

- Gözetimli öğrenme
- Gözetimsiz öğrenme
- Karma öğrenme

#### **4.5.1.Gözetimli öğrenme**

Gözetimli öğrenme, bu yaklaşımlar arasında çoğunlukla tercih edilen öğrenme yaklaşımı olarak göze çarpmaktadır. Yapay sinir ağının eğitilmesi için üretilmiş olan eğitim veri kümesinin, probleme ait önceki veriler ile birlikte yine bu verilere ait çözümleri de kapsadığı durum “Gözetimli Öğrenme” olarak adlandırılmaktadır. Gözetimli öğrenme yaklaşımı, yapay sinir ağı modeline çıktılarını karşılaştırması için gerçek çözümlerin verilmesi, özetle ağa her bir aşamada beklenen çıktının aktif şekilde sunulması kuralını kapsadığından gözetimli öğrenme olarak isimlendirilmektedir (Murray, 2003).

Gözetimli öğrenmede eğitim zamanı, yapay sinir ağının ürettiği tahmini çıktılarının gerçek çözümler ile karşılaştırılması, sonuçlarının hata payının tespit edilmesi ve modele ait yapay sinir hücreleri arasındaki bağlantıların güçlerini bu hatayı en minimize edecek şekilde güncellemesi şeklinde meydana gelmektedir (Hamzaçebi ve Kutay, 2004).

#### **4.5.2.Gözetimsiz öğrenme**

Gözetimsiz öğrenme, ağın eğitim aşamasında ağ tarafından oluşturulan tahmini çözümlerin kıyaslanabileceği gerçek çözümlerin mevcut olmamasıdır. Bu çeşit durumlarda, yapay sinir ağı modeli matematiksel olarak girdilerin belli başlı özelliklerini keşfetmeye ve bunlarda görülen değişikliklere göre kendi cevap algoritmasını optimize etmeye çalışmaktadır (Kröse ve Smagt, 1996).

Gözetimsiz öğrenme özelinde oluşturulan çeşitli hata tanımları vardır. Bunlardan en çok kullanılanı, eğitim aşamasında sunulan veri seti ve bu grubu temsilcisi olan ağırlık vektörünün farkının hata göstergesi olarak kullanılmasıdır (Şahin, 2002).

#### **4.5.3. Karma öğrenme**

Yapay sinir ağına eğitim veri kümesine ait gerçek çözümler sunulmadığında gözetimsiz öğrenme özelliği taşımakta iken; ağın ürettiği çözümler için “iyi” ya da “kötü” şeklinde tahminde bulunulabiliyor ise gözetimli öğrenme olarak düşünülebilmektedir (Şahin, 2002). Ağ yapı olarak her iki öğrenme yapısına ait özellikleri taşıdığına ise bu öğrenme karma olarak adlandırılabilir.

#### **4.6.Yapay Sinir Ağlarında Öğrenme Kuralları**

Yapay sinir ağları için birden fazla öğrenme kuralı algoritması bulunmaktadır. Bu kurallar aşağıdaki şekilde özetlenebilir:

1. Hebb Kuralı
2. Hopfield Kuralı

### 3. Kohonen Kuralı

### 4. Delta Kuralı

#### 4.6.1. Hebb kuralı

Hebb kuralı, yapay sinir ağının bağlantı adeti farklılaştırıldığında, ağın öğrenebiliyor olduğunu kabul eder. Bir nöron başka bir nörondan girdi aldığı anda bu iki nöron yüksek bağlantılıysa, kısaca matematiksel ifade ile aynı işaretle ise, nöronlar arası ağırlık kuvvetlenmektedir.

#### 4.6.2. Hopfield kuralı

Hopfield kuralı, ağa ait elemanların bağlantılarının ne kadar kuvvetlendirilmesi ya da zayıflatılması gerektiği sorusuna cevap verir. Bu işlem öğrenme katsayısı ile yapılır ve öğrenme katsayısı kullanıcının belirlediği 0-1 aralığında sabit ve (+) bir değerdir.

#### 4.6.3. Kohonen kuralı

Bu kuralda ağ kendi kendini danışmansız eğitebilmektedir. Bu aynı zamanda paralel olarak en uygun sonucu belirleyebilmek için düğümlerin yarışması sayesinde mümkün olmaktadır. Sistem girdileri gruplandırmak için kullanacağı özellikleri kendi belirlemektedir. Bu sebeple ağın bağlantı ağırlıklarına başlangıca ait değerlerin sunulması ve girdilerin normalizasyonu gerekmektedir.

#### **4.6.4. Delta kuralı**

Hebb kuralının gelişmiş halidir. Beklenen ve gerçekleşen çıktı farkını minimize etmek amacıyla ağırlıkların belirli aralıklarda değiştirilmesi gerektiğini kabul eder. Ağdaki minimum hata için, ağırlıklar sürekli güncellenmektedir ve temelde en küçük kareler kuralını temel alır (Arbib, 2003).

#### **4.7. Yapay Sinir Ağı Çeşitleri**

Literatürde birçok çeşitte yapay sinir ağı bulunmaktadır. Ancak çözümü istenen problemler farklılık gösterse de yapay sinir ağlarını belli başlıklar altında gruplandırmak mümkündür. Bu gruplama 2 yöntem ile yapılabilir (Arbib, 2003):

Yapay sinir ağları mevcut çıktısının kesikli ve sürekli olma durumuna göre iki yöntemle ele alınabilir. Kesikli değişkenlerden oluşan girdiler sonlu sayıda nitel değerler alabilirken; sürekli değişkenler ise sayısal olarak ifade edilebilen uzunluk, ağırlık gibi ölçülebilen değerlerdir.

Yapay sinir ağları, sinir veya düğüm olarak adlandırılan işlem elemanlarının birlikteliğinden meydana gelmektedir. Yapay sinir ağı modelleri, sinirleri birbirine bağlayan bağlantıların yönlerine göre veya ağındaki işaretlerin akış yönüne göre birbirinden farklılaşmaktadır. Bu modeller ileri beslemeli ve geri beslemeli olmak üzere iki gruba ayrılmaktadır (Serttaş, 2011).

##### **4.7.1. İleri beslemeli ağlar**

İleri beslemeli ağlar içinde bilgi iletilmesi, girdi katmanı, gizli katman ve çıktı katmanı sırasıyla gerçekleşmektedir. Bu akış geri besleme olmadan tek yönlü

olacak şekilde yapılmaktadır. Bir katmandaki yapay sinir hücreleri, bir önceki YSA hücreleri aracılığıyla beslenmektedir. Yapay sinir ağları içerdikleri katman adetine göre tek katmanlı veya çok katmanlı ileri beslemeli yapay sinir ağları şeklinde gruplandırılabilir.

#### **4.7.2. Geri beslemeli ağlar**

Standart olarak geri besleme durumu, hataları geri yönlü olacak şekilde çıkıştan girişe doğru düşürmeye çalıştığı için bu şekilde adlandırılmaktadır. İlgili geri beslemeli ağa ait modelde giriş, gizli ve çıkış olarak adlandırılan üç katman yer alır fakat problemin özellikleri de dikkate alınarak gizli katman sayısı artırılabilir (Serttaş, 2011).

Bu çalışmada Çok Katmanlı İleri Beslemeli Ağ kullanılmıştır. İlgili ağlar girdi ile çıktı sinir hücreleri arasında minimum bir adet olacak şekilde gizli sinir hücresi taşınır (Grossberg, 1992).

#### **4.8. Yapay Sinir Ağları Çalışma Prosedürü**

Yapay sinir ağlarına ait çalışma mekanizmasında sırayla aşağıdaki adımlar meydana gelir (Arbib, 2003):

1. Örneklerin toplanması: Ağ öğretilen durumun, geçmişteki örneklerinin toplanmasıdır.

2. Ağın topolojisinin belirlenmesi: Ağdaki katmanlar ve bu katmanların işlem eleman sayısı bulunur.

3. Öğrenmeye ait parametrelerin bulunması: Öğrenme ve momentum katsayısıyla toplama ve aktivasyon fonksiyonları bulunur.

4. Ağırlıklara ait başlama değerlerinin belirlenmesi: Giriş değerleri ve ara katmanlarda ağırlıklar rastsal şekilde (-0.1 , 0.1) aralığında seçilir.

5. Öğrenme seti içerisinde örneklerin seçimi ve ağıya sunulması: Öğrenme setinin içeriği ağıya gösterilir.

6. Öğrenme esnasında ileri hesaplamaların gerçekleştirilmesi: Girişteki vektör için çıktı ve sonuçtaki hata değeri belirlenir.

7. Gerçek ve tahmini çıktıların kıyaslanması: Gerçekleşen ve beklenen çıktı değerleri karşılaştırılarak aradaki fark ağına hatası olarak belirlenir.

8. Ağırlıkların değişimi: Geriye doğru hesaplamalar ile genel hata ağına bağlantı ağırlıklarına yayılır.

#### **4.9. Yapay Sinir Ağları ve Tahmin Modelleri**

Üretici ve perakendeci birçok satıcı kesin satışını tahmin etmek ister. Özellikle perakendeciler, geçmişe dair satış verileri ile stokları özelinde satış tutarlarını belirlemeyi hedefler. Bu ihtiyacı karşılamak için büyük veri tabanlarını analiz eden yapay sinir ağları kullanılır (Thall,1992).

Yapay sinir ağları ile yapılan tahminlemeler esnasında diğer matematiksel modellerde de kullanıldığı gibi geçmişe ait veriler kullanılmaktadır ve



parametreler değerlendirilirken en küçük kare hatasına ulaşılmaya çalışılır. Optimum ağırlık değerini bulmak için sinir ağı eğitilir ve en uygunu tespit edilene kadar sinir ağı bir dizi iterasyona tabii tutulur (Denton, 1995).

Yapay sinir ağları, ideal koşulların olmadığı durumlarda talep tahmininde regresyon yöntemine göre daha sağlıklı sonuçlar sağlar. Regresyona göre daha sağlıklı sonuçların alındığı durumlar şöyle ifade edilir (Denton, 1995):

Matematikselsel bir modelde tahminleme yapılırken değişkenler arasındaki ilişkileri açıklayan bir fonksiyonu varsayım olarak benimsemelidir. Yapay sinir ağları için benzer bir yapı gerekli değildir ve bağımsız değişkenler arasında ilişki var ise bunu kendisi öğrenebilir.

Literatürde gelecek tahmini ile ilgili birçok çalışma yer almaktadır. Bu yaklaşımları 2 ana başlıkta toplamak mümkün olabilir. Bu başlıkları tahminlerin sayısal ya da sezgisel yaklaşımlarla yapılmasından yola çıkarak nicelikselsel modeller ve nitelikselsel modeller olarak belirleyebiliriz.

Nitelikselsel modeller, şahsi düşünce ve fikirleri de içinde barındırırken nicelikselsel modeller ise bunun aksine öznellikten uzak istatiki ve matematikselsel yaklaşımlar ile problemlere çözüm arayan modellerdir (Kobu, 1984).

Bu çalışma için uygulaması seçilen yapay sinir ağları tahmin modeli uygun bir zaman serisi örneğidir.

Tahmin modellerinde genel olarak yapay sinir ağı ile modellemenin tercih edilmesi aşağıdaki maddeler ile özetlenebilir:

Gelecek tahmini yapılırken yeterli şekilde geçmiş verilerle eğitilen bir ağ bu veriler arasındaki karmaşık ilişkiler belirtilmemiş olsa bile bu ilişkileri doğru bir şekilde bulabilir.

Ağ, eğitim sırasında daha önce karşılaşmadığı durumları da genelleme özelliği sayesinde çözümleyebilme özelliğine sahiptir.

Ağın kesikli fonksiyonları da tanımlayabilme özelliği sayesinde doğrusal olmayan problemlerde de kullanımı mümkündür (Zhang vd., 1998).



## 5. ELEKTRONİK PERAKENDE SEKTÖRÜNE AİT BİR TALEP TAHMİNİ UYGULAMASI

Çalışmada talep tahmini uygulaması, Türkiye'nin öncü elektronik perakende şirketlerinden birinin 'notebook' ürün grubu özelinde satış datalarından yola çıkarak yapay sinir ağları ile WEKA programında çözülmüştür.

Ele alınan şirkette uygulama kapsamında girdi olarak Ocak 2015 – Aralık 2017 tarihleri arasındaki aylık satış adetleri kullanılarak, gelecek aylar için satış tahmini yapılmıştır.

### 5.1. Yapay Sinir Ağı Mimarisi

Çalışmada talep tahmini yapılırken WEKA programı kullanılmıştır. WEKA'da yapay sinir ağları ile çözüm yoluna başvurulmuş ve Multilayer Perceptron algoritması çalıştırılmıştır. Modelde mevsimselliği verebilmek için ay bazında veriler kullanılmış ve ay verisinin de modele girdi olarak eklenmesi kararına varılmıştır. Seçilen perakende şirketinden sağlanan Ocak 2015 – Aralık 2017 yılları arasındaki 3 yıla ait 36 adet aylık satış verisi, 2015 ve 2016 yıllarına ait veriler eğitim, 2017 yılına ait veriler test datası olarak seçilerek farklı ağ yapıları ve öğrenme parametrelerine sahip çeşitli modeller kurulup denemeler yapılmış ve eğitimler gerçekleştirilmiştir.

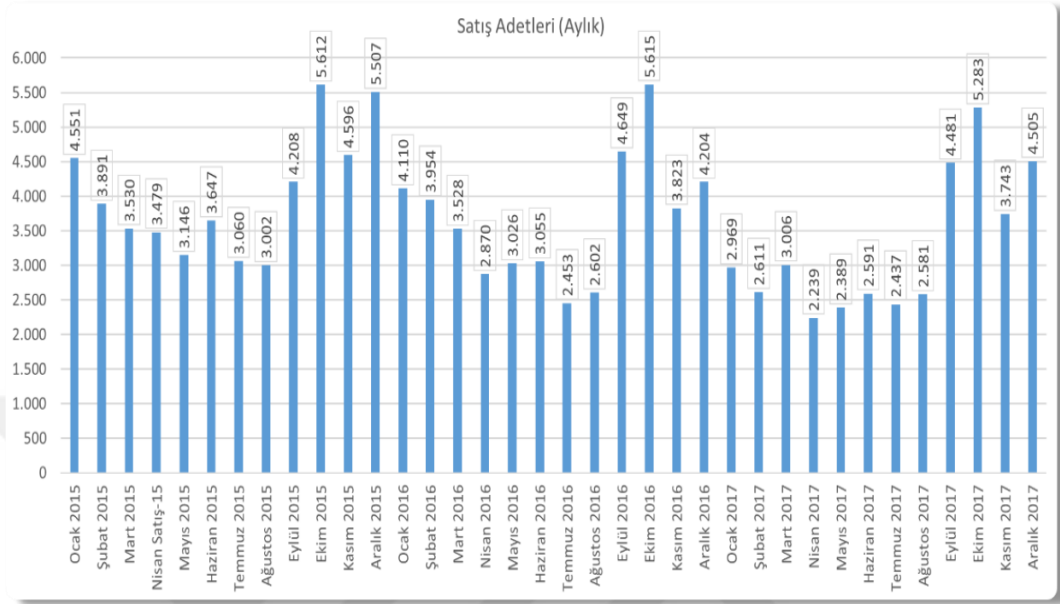
Verilerin oransal olarak yaklaşık %67'si eğitim için kullanılmıştır. Ağların performansını ölçmek için ise eğitim setinde kullanılmayan ve test için ayrılan veriler ile modeller test edilerek en optimal sonuç bulunmaya çalışılmıştır. Girdi katmanı, aylık tarih rakamları olarak bir hücreden, ek olarak çıktı katmanı ise satış verilerinden meydana gelen bir hücreden oluşmaktadır. Gizli katmanda ise farklı sayıda hücre yer alabilir, çalışmanın devam eden kısmında uygun gizli katman hücre sayısını ve bu katmalardaki nöron sayılarını bulmak adına

denemeler yapılmıştır. Yapay sinir ağlarında gizli hücre sayısını bulmak için ise “geometrik piramit kuralı” yöntemi kullanılmıştır. Bu kurala göre, girdi katmanından çıktı katmanına doğru hücre sayısının azalması gerekmektedir.

Bu çalışma kapsamında piramite göre gizli hücre sayısı, ağa ait girdi hücre sayısının iki katı olacak şekilde iki adeti geçmemelidir. Ayrıca bu sayı, girdi hücre adeti ve çıktı hücre adeti çarpımının karekökünden de az olmamalıdır. Bu koşullarda mevcut çalışmada farklı farklı denemeler yapılmıştır.

Bilgiler ağa girdi katmanı ile dahil edilerek bir sonraki adımda gizli katmanda bilgi ağırlık değerleri kullanılıp çıktılar oluşturulmuştur. Çıktı katmanına gelen bilgiyi işlemek için kullanılacak doğru ağırlıkların bulunması adına ise eğitim dataları ile girdiler WEKA programında eğitilmiştir. Başlangıçta rastgele belirlenen ağırlıklar, eğitim aşamasında ağa gösterilen her örnek ile ağırlık öğrenme kuralına göre değiştirilerek ilerlenmiştir. Burada amaç mevcut ağa en uygun ağırlık değerinin bulunmasıdır. Belirlenen ağırlıkların başlı başına ne ifade ettiği bilinmemektedir. Ağ girdiler ile ilgili sonucu bu ağırlıklar yardımıyla verdiği için, ağırlık zekası bu ağırlıklara bağlıdır denilebilir.

Grafik 5.1.'de çalışma kapsamında kullanılan 36 aylık eğitim ve test verileri belirtilmiştir:



Grafik 5.1. Geçmiş Aylara Ait Satış Adetleri

Eğitim verileri ağa sunularak ağın öğrenmesi gerçekleştirilmiş ve modeller arasında eğitim verileri ve test verileri için farklı farklı hata kareleri ortalaması (MSE), ortalama mutlak yüzde, hata (MAPE) ve ortalama mutlak hata (MAE) istatistiksel hata değerlerinden en küçük hata değerini veren YSA modeli seçilmiştir. Eğitimde ağa tanıtılmış olan veriler giriş olarak sunulduğunda çıkış değerlerinin ise gerçek değerlere oldukça yakın çıktığı gözlemlenmiştir. Ancak sistemin mevcut durumda tanımadığı veriler ile test yapıldığında ise gerçek değerler ve test setinden tahmin edilen değerler anlamlı olacak şekilde farklı sayılmaktadır. Çalışma kapsamında ilk olarak çevrim sayısı sabitlendiğinde öğrenme ve momentum katsayılarının en optimum değerleri belirlenmeye çalışılmıştır. Hücre sayısı, momentum katsayısı ve öğrenme katsayısındaki değişimler tahmin sonuçlarını doğrudan etkilemektedir. Bu yüzden mümkün olduğunca fazla deneme yapıp sonuçlar karşılaştırılmıştır.

## 5.2. Yapay Sinir Ağı WEKA Uygulamaları

Çalışma kapsamında ilk olarak öğrenme katsayısını bulabilmek için eğitim ve test verileri için 0.1-0.9 değerleri arasında deneme yapılmıştır. Sonraki adımda bulunan optimal öğrenme katsayısı dikkate alarak momentum katsayısı 0.1-0.9 değerleri arasında denenmiştir, belirlenen bu optimal aralıklardan hareket ile elde edilen sonuçlar çalışmada değerlendirilmiştir.

### 5.2.1. Yapay sinir ağlarının eğitimi ve testi

Başlangıçta rastgele belirlenen ağa ait ağırlık değerleri, ağa sunulan örnekler ile birlikte değiştirilmektedir ve ağırlık değerlerinin değişimi işlemi "ağın eğitilmesi" olarak adlandırılmaktadır. Öğrenmede asıl amaç, ağa uygun olan optimal ağırlık değerlerini seçerek, problem için en doğru çıktıları üretmektir.

Yapay sinir ağlarında eğitim süreci, belirli kurallar ile olmaktadır. Ağırlıkların değiştirilmesi bu kurallara göre yapılır. YSA doğru ağırlık değerlerine ulaştığı zaman, problem için genellemeler yapabilir duruma gelir ve ağın bu özelliği ağın öğrenmesi olarak adlandırılmaktadır (Öztemel, 2012).

Eğitim ve öğrenme YSA için aynı kavramlar değildir. Eğitme, ağın öğrenebilmesi amacıyla gerçekleşen adımlardır, öğrenme ise bu eğitimin sonucudur. Eğitim, mevcut problemin özelliğine göre öğrenme kuralının yapay sinir ağına nasıl uyarlanabileceğini gösterir (Özcan, 2007).

Çalışmamızda yapay sinir ağı tasarlanırken 36 adet aylık satış verisi, 2015 ve 2016 yıllarına ait veriler eğitim ve 2017 yılına ait veriler test verisi olacak şekilde ikiye ayrılmıştır. Yapay sinir ağının eğitimi sonrasında, ağın öğrenip öğrenmediğini bulmak için denemeler yapılarak ağ test edilmiştir. Ağ test

edilirken ağı a ait ağırlık deęerleri deęiştirilmemiř ve çıktılar gözlemlenmiřtir. Test iřlemi bittikten sonra ağıdaki çıktı sonuçları deęerlendirilmiřtir. Çıktı deęerleri karřılařtırmalarda ya da yapılacak hesaplamalarda kullanılabilir. Test sonucunda ise elde edilen sonuçların doęruluk derecesi ile eęitim performansına karar verilmiřtir.

İlgili alıřmada eęitim seti, mevcut ağıın geliřiminde; test seti de modelin performansının ölçülmesinde kullanılmıřtır. Ağı eęitilirken, hata oranlarının yükselmeye bařladıęı noktada eęitime son verilmiřtir. Bu noktadaki deęerler de uygun deęerler olarak alınmıřtır.

### **5.2.2. Öğrenme ve momentum katsayısının belirlenmesi**

Öğrenme katsayısı, ağırlıkların bir sonraki düzeltmede ne kadar deęiřmesi gerektięini göstermektedir. Öğrenme katsayısının doęru seilmesi ağıın öğrenme performansında oldukça önem tařımaktadır. Bu katsayı ağı a ait öğrenme hızını etkilemektedir. Küçük deęerler, ağıın öğrenme süresini arttırırken büyük deęerler yerel çözümler arasında ağıın dolařmasına neden olmaktadır. Yapılan denemeler ile öğrenme katsayısının optimal deęerinin 0.2 - 0.4 arasında olduęu üzerinde yoęunlařılmıřtır. alıřma kapsamında ise 0-1 deęerleri arasında tüm öğrenme katsayıları için denemeler yapılmıřtır.

Uygun öğrenme katsayısı belirlendikten sonra bu deęer sabit tutularak momentum katsayısı için denemeler yapılmıřtır. Momentum katsayısı, her bir döngünün bitiminde gerekleřen parametre deęiřiminin, ardındaki parametreye etki oranını gösterir. Böylece, ağıın eęitimi ařamasında ağırlık deęiřim deęerinin, sonraki deęiřime ne kadar miktarda yansyacaęı bulunur (Altınıřık, 2012). Momentum katsayısı bir önceki iterasyona ait deęiřimin belirli bir oranının yeni deęiřime eklenmesi ile elde edilir. Bu deęerin küçüklüęü yerel çözümlerden uzaklařmayı zorlařtırırken, büyüklüęü ise tek bir çözüme ulařmayı

zorlaştırabilir. Momentum katsayısı öğrenme performansını değiştirmektedir. Momentum katsayısı, ağ yerel çözümlere takılırsa, sıçramayla daha uygun sonuçlar elde edilmesine yardımcı olur. Momentum katsayısı 0 değerini aldığı anda, ağırlık değişiminde geçmiş değişimin dikkate alınmaması, 1 değerini aldığı anda ise ağırlık değişiminin daha çok geçmiş değişime bağıllığı demektir (Hamzaçebi, 2011). Çok büyük değerler uygun sonuca ulaşırken sorunlar yaşatabilir. Bu değerin 0.6 - 0.8 arasında en optimal olduğu düşünülmektedir.

### **5.2.3. Çevrim sayısının belirlenmesi**

Belirli bir deneme sayısından sonra ağın öğrenmesinin sona erdiği düşünülür. Bunun sonucunda ağ artık öğrenemez ve daha uygun bir sonuç elde edilemez. Momentum katsayısı 0.1 ve 0.2 öğrenme katsayısı 0.1 ve 0.5 alınarak en uygun çevrim sayısı bulma denemeleri yapılmıştır. Bu denemelerde veri sayısının az olması sebebiyle validasyon datası kullanılmamıştır. 500 - 2000 arasında çevrim sayıları denenmiş ve en uygun çevrim sayısının 2000 olduğu belirlenmiştir ve bu döngü sayısında modelin eğitiminin durduğu gözlemlenmiştir.

### **5.2.4. Nöron sayısının belirlenmesi**

Ağın yapısal niteliklerinden biri de her katmana ait nöron sayısıdır. Bir katmanda yer alacak nöron sayısının olabildiğince az olması uygundur. Nöron sayısının az olması YSA'nın genelleme yeteneğini yükseltmektedir. Gereğinden çok olması ağın verileri ezberlemesine neden olabilmektedir. Yapay sinir ağları tahminlerine ait problemlerde nöron sayısı, gecikme sayısı ile doğrudan bağlantılıdır ve bu sayıyı tespit edebilmek için belirli bir yol yoktur.



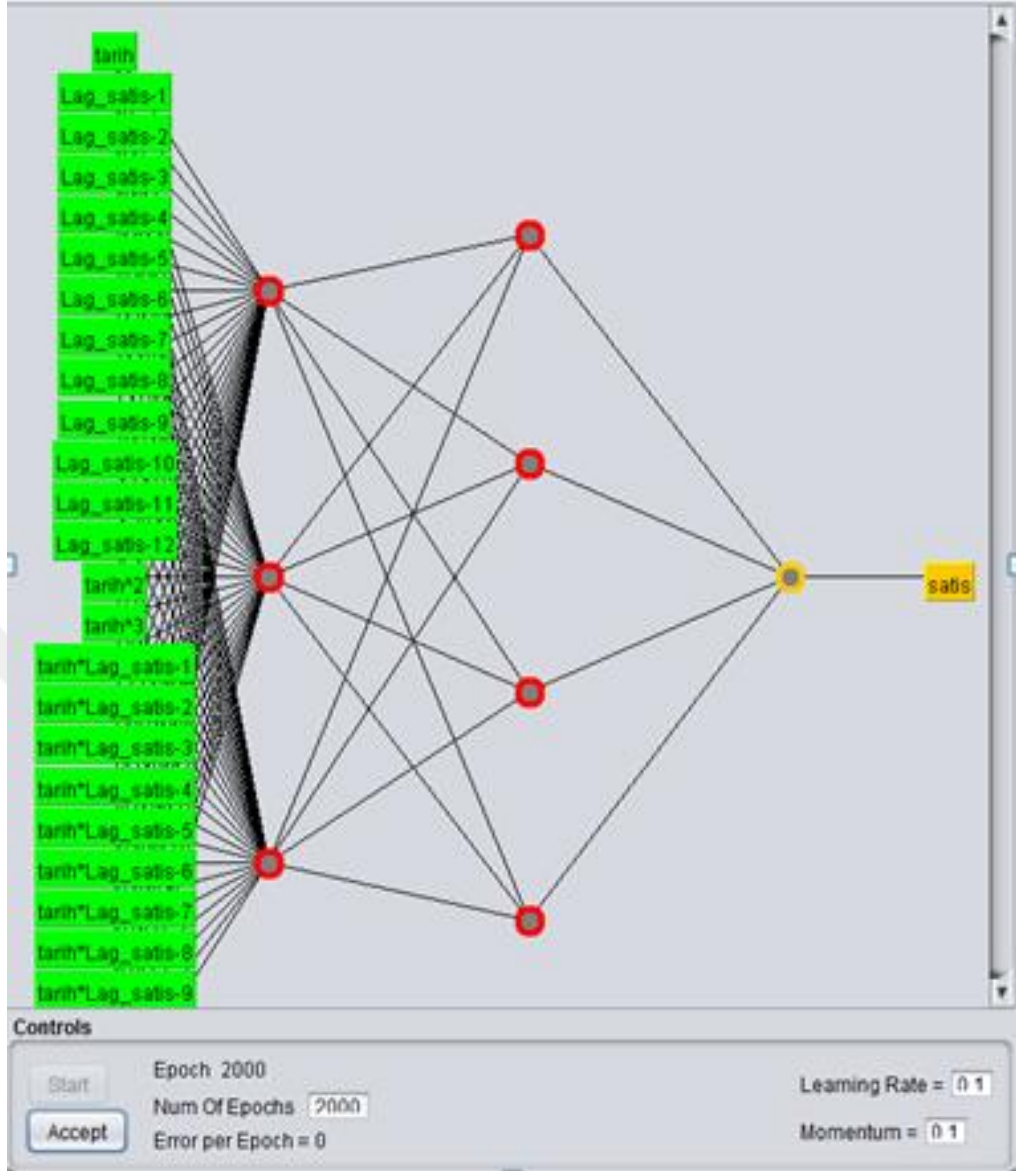
### 5.2.5. Gizli hücre sayısının belirlenmesi

Momentum katsayısı 0.1, öğrenme katsayısı 0.1, çevrim sayısı 2000 alınarak sonrasında nöron sayısı ve gizli hücre sayısının hesaplanmasına geçilmiştir. Gizli hücre sayısı 1' den giriş hücre sayısının iki katı olan 2'ye kadar denemeler yapılmıştır. En iyi hücre sayısının 2, bu katmanlardaki nöron sayılarının ise sırasıyla 3 ve 4 olduğu belirlenmiştir.

Aşağıda gizli katman ve nöron sayısını belirlemek adına eğitim datası olarak seçilen 24 aylık veriye ait MAPE değerleri Tablo 5.1.'de sıralanmıştır ve en düşük MAPE değerini veren model seçilerek WEKA görseli Grafik 5.2.'de gösterilmiştir.

Gizli Katman Sayısı	Nöron Sayısı1	Nöron Sayısı2	Eğitim Datası MAPE
1	1	-	6,29
1	2	-	0,51
1	3	-	0,44
1	4	-	0,45
1	5	-	0,96
2	1	2	6,22
2	1	1	6,23
2	1	3	6,24
2	1	4	6,27
2	1	5	6,30
2	2	5	0,49
2	2	2	0,49
2	2	1	0,66
2	2	3	0,86
2	2	4	0,98
2	3	3	0,40
2	3	4	0,32
2	3	2	0,50
2	3	5	0,60
2	3	1	0,70
2	4	3	0,90
2	4	4	0,40
2	4	1	0,40
2	4	5	0,50
2	4	2	0,80
2	5	4	0,40
2	5	1	0,50
2	5	2	0,67
2	5	5	0,70
2	5	3	0,80

Tablo. 5.1. Gizli Hücre ve Nöron Sayısının Belirlenmesi için Denemeler



Grafik 5.2. Uygun Gizli Hücre ve Nöron Sayısı (Weka, 2019)

### 5.2.6. Seçilen tahmin modeli sonuçları

Aşağıdaki Tablo 5.2’de ilk 24 aylık veri eğitim, Tablo 5.3’te son 12 aylık veri ise test datalarıdır. Bu eğitim ve test datalarına ait hata değerleri (MAE, MAPE ve MSE)’ de ilgili tabloda 4, 5 ve 6. Sütunlarda gösterilmiştir. Tablo 5.4’te modelde kullanılan eğitim ve test kümesi verileri ile tahminler incelendiğinde YSA tahmin modeli ile hesaplanan değerlerin gerçek değerlere oldukça yakın olduğu gözlemlenmektedir. Bu değerler ve karşılaştırmalar ağın etkili bir şekilde duyarlı sonuçlar ürettiğini ve gelecek aylık satış tahminlerinin modellenmesi için yeterli doğruluğa ve güvenilirliğe sahip olduğunu göstermektedir.



AY	Satış Adet	Satış Adet Tahmin	MAE	MAPE	MSE
Oca.15	4.551	4.411	140	3%	19.600
Şub.15	3.891	3.105	786	25%	617.796
Mar.15	3.530	3.090	440	14%	193.160
Nis.15	3.479	3.033	446	15%	198.470
May.15	3.146	2.867	278	10%	77.340
Haz.15	3.647	2.738	909	33%	825.736
Tem.15	3.060	3.327	267	8%	71.396
Ağu.15	3.002	2.095	907	43%	821.742
Eyl.15	4.208	2.882	1.327	46%	1.760.664
Eki.15	5.612	3.981	1.631	41%	2.661.466
Kas.15	4.596	3.208	1.388	43%	1.927.377
Ara.15	5.507	3.990	1.517	38%	2.301.592
Oca.16	4.110	2.849	1.261	44%	1.590.878
Şub.16	3.954	2.955	999	34%	997.402
Mar.16	3.528	2.683	845	31%	714.025
Nis.16	2.870	2.585	285	11%	81.282
May.16	3.026	4.854	1.828	38%	3.341.950
Haz.16	3.055	2.139	916	43%	838.323
Tem.16	2.453	1.758	695	40%	483.581
Ağu.16	2.602	1.882	720	38%	518.256
Eyl.16	4.649	3.197	1.452	45%	2.106.852
Eki.16	5.615	3.961	1.654	42%	2.736.047
Kas.16	3.823	2.795	1.028	37%	1.057.195
Ara.16	4.204	3.086	1.118	36%	1.249.700

Tablo 5.2. Seçilen Modelde Kullanılan Eğitim Kümesi Verileri

AY	Satış Adet	Satış Adet Tahmin	MAE	MAPE	MSE
Oca.17	2.969	3.250	280	9%	78.624
Şub.17	2.611	2.398	213	9%	45.326
Mar.17	3.006	2.901	105	4%	11.025
Nis.17	2.239	2.097	142	7%	20.221
May.17	2.389	2.210	179	8%	31.898
Haz.17	2.591	2.357	234	10%	54.803
Tem.17	2.437	2.190	247	11%	61.108
Ağu.17	2.581	2.398	184	8%	33.746
Eyl.17	4.481	3.986	495	12%	245.124
Eki.17	5.283	4.878	405	8%	164.025
Kas.17	3.743	3.328	415	12%	172.308
Ara.17	4.505	3.987	518	13%	267.806


Tablo 5.3. Seçilen Modelde Kullanılan Test Kümesi Verileri

Eğitim Kümesi MAE	951,5
Test Kümesi MAE	284,7
Eğitim Kümesi MAPE	31,60%
Test Kümesi MAPE	9,30%
Eğitim Kümesi MSE	1.132.992,90
Test Kümesi MSE	98.834,50

Tablo 5.4. Modelde Kullanılan Eğitim ve Test Kümesi Verileri ile Tahmin

## 6. SONUÇ VE ÖNERİLER

Tahmin, gelecekte neyin nasıl olacağını öncesinde belirlemeye çalışmaktır. Hemen hemen tüm yönetsel kararlar geleceğe tahminlere dayanmaktadır. Bu sebeple tüm şirketler gelecekte yaşayabileceği belirsiz durumları öncesinde tahmin ederek, bunlara yönelik önlemler ve iyileştirmeler yapmalıdırlar. Bu sebeple uygulamasını yaptığımız şirket probleminin çözümünde bir tahmin aracı olarak yapay sinir ağları kullanılmıştır. Optimal sonuca ait yapay sinir ağında 2 gizli katman ve bu katmanlarda sırasıyla 3 ve 4 nöron yer almaktadır. Optimal sonuca ait yapay sinir ağı yapısı aşağıda Grafik 6.1.'de gösterilmektedir:



Grafik 6.1. Optimal Sonuca Ait Yapay Sinir Ağı Yapısı (Weka, 2019)

Uygulama çalışmamızda, 2015-2017 yılları arasında Türkiye'nin öncü elektronik perakende şirketlerinden birinin 'notebook' ürün grubu özelinde satış dataları adet cinsinden verilmiştir. 2015 (Ocak) - 2017 (Aralık) yılları arasındaki 36 adet veriden ilk 24'ü ağın eğitimi için, son 12'si ise ağın test edilmesi için kullanılmıştır. Yapılan tahmin sonucunda MAPE, MAE ve MSE hata değerleri yorumlanarak Çizelge 6.1.'deki değerlere ait sonuçlar Çizelge 6.2.'de ilgili sonuçlar elde edilmiştir. Şekil 6.1.'de ise bu değerlere ait sonuç grafiği gösterilmiştir.

Öğrenme Katsayısı	Momentum Katsayısı	Çevrim Sayısı	Gizli Katman Sayısı	Nöron Sayısı1	Nöron Sayısı2
0,1	0,1	2000	2	3	4

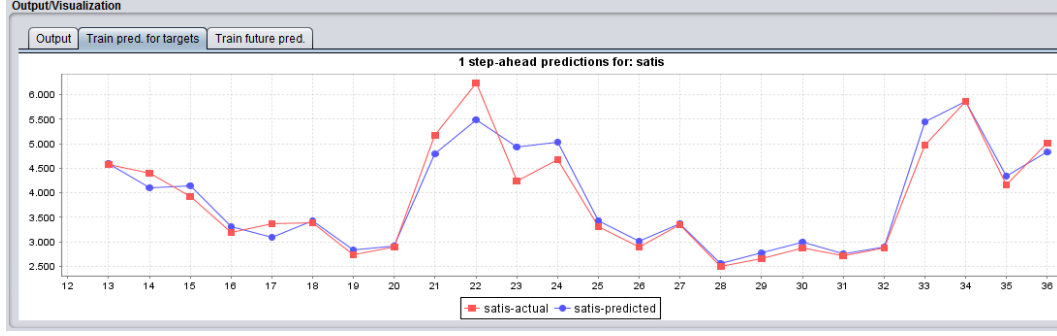
Çizelge 6.1. Optimal Yapay Sinir Ağı Parametreleri

Ay	Tahmin
2018 Ocak Tahmin	4.148
2018 Şubat Tahmin	2.901
2018 Mart Tahmin	5.214
2018 Nisan Tahmin	4.765
2018 Mayıs Tahmin	3.285
2018 Haziran Tahmin	4.209

Çizelge 6.2. Gelecek 6 Aylık Tahmin Değerleri

En başarılı olan kombinasyonun gerçek veri ile karşılaştırılmış hali aşağıdaki WEKA grafiğinde gösterilmiştir. Yapay sinir ağının genel olarak test verisine çok yakın sonuçlar verdiği Şekil 6.1.'de görülmektedir.





Şekil 6.1. Optimum Sonucun Gerçek Veri ile Karşılaştırılması (Weka, 2019)

Yapay sinir ağları gelecek tahminlerinde etkili bir yöntem olarak kullanılabilir. Tahminin doğruluğu modellerin hatasız olması koşuluyla verilerdeki hata miktarıyla yakından ilişkilidir. Uzak geleceğin tahmin edilmesinde YSA neden sonuç modelleri girdi parametrelerinin gelecek değerlerinin uygun belirlenmesi halinde daha doğru tahminlemeler yapabilirken YSA zaman serisi modelleri yakın gelecekteki değerlerin tutarlı olması durumunda daha doğru tahminlerde bulunabilmektedir.

Sürenin uzaması ve verilerin değişkenliği YSA zaman serisi modellerinin tahmin doğruluğunu azaltır. Uzak geleceğin tahmin edilmesi için YSA sebep sonuç modelleri kullanılmalıdır. Yakın geleceğin tahmin edilmesinde ise YSA zaman serisi modelleri kullanılabilir.

Yapay Sinir Ağlarının günümüze kadar keşfedilen ve ilerleyen süreçte de devam edecek bu avantajlarından hareketle hazırlanan çalışmamızda YSA modellerinin diğer modellere kıyasla daha düşük hatalar ile sonuçlanmasından dolayı daha uygun ve başarılı olduğu görülmüştür. Ülkemizde hem Yapay Sinir Ağları ile hem de gelenekselleşen zaman serileri tahmin yöntemleri ile satışların modellenmesi ve tahmin edilmesine ilişkin araştırmaların sınırlı olduğu ve çalışma için verileri kullanılan Türkiye'nin öncü perakende şirketinde mevcut olan herhangi bir satış tahminleme yönteminin kullanılmadığı dikkate

alındığında, bu çalışmanın Türkiye'deki satış tahminleme literatürüne ve buradaki yöneticilerin gelecek planlama çalışmalarına önemli katkılar sağlayacağı düşünülmektedir.

Her geçen gün gelişmeye devam eden yapay sinir ağları gelecekte, sistemlerin kalitesinin artırılmasına yönelik de önemli yarar sağlayacaktır.

İleriye yönelik yapılacak çalışmalarda, zaman serileri ve gri tahminleme gibi farklı yöntemler kullanılarak yapılan tahminler YSA sonuçları ile karşılaştırılabilir.

## KAYNAKLAR

- Acar, N., 1989. Üretim Planlaması Yöntem ve Uygulamaları, Yeniçağ, Ankara.
- Agrawal, D. ve Schorling, C., 1996. Market Share Forecasting: An Empirical Comparison Of Artificial Neural Networks And Multinomial Logit Model, Journal Of Retailing, 72, 4, 383-407.
- Aladag, C. H., Basaran, M. A., 2009. Egrioglu E., Yolcu, U. and Uslu V. R. Forecasting in high order fuzzy time series by using neural networks to define fuzzy relations, Expert Systems with Applications.
- Alkan, A., 2019. Beyin Tümörü Teşhisi Tahmini, Kahramanmaraş Sütçü İmam Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Kahramanmaraş, Türkiye.
- Altınışık, A., 2012. Toprak İşlemede Traktör Çeki Performansının Yapay Sinir Ağları ile Analizi, Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Arbib, M.A., 2003. The handbook of brain theory and neural networks, second edition. Massachusetts Institute of Technology. USA.
- Asilkan, Ö. ve Irmak, S., 2009. İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin Edilmesi, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 14, 375-391.
- Avcı, E., 2009. Yapay Sinir Ağları Modelleri \_le Hisse Senedi Getiri Tahminleri, Marmara Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 26-1, 443-461.
- Aydoğan, B., Ayat, B., Öztürk, M.N., Çevik, E.Ö. ve Yüksel, Y., 2010. Current velocity Forecasting in Straits with Artificial Neural Networks, a Case Study: Strait of İstanbul, Ocean Engineering, 37,5-6, 443-453.
- Aygören, H., 2012. İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini, Uluslararası Alanya İşletme Fakültesi Dergisi.
- Babic, D., Kuljanin, J. ve Kalic, M. 2014. Market Share Modeling İn Airline Industry. An Emerging Market Economies Applicaiton, Transportation Research Procedia, s. 384-392.
- Barghash, M.A. ve Santarisi, N.S., 2004. Pattern recognition of control charts using artificial neural networks – analysing the effect of the training parameters, Journal of Intelligent Manufacturing, 15, 635-644.

- Bolt, G., 1981. Market and Sales Forecasting, A Total Approach. (Second Edition). London: Kogan Page Limited.
- Bolt, G., 1994. Market and sales forecasting a total approach, Kogan Page, Londra.
- Budak, H., 2012. Online Academic Journal of Information Technology.
- Buhari, M. ve Adamu, S., 2012. Short Term Load Forecasting Using Artificial Neural.
- Cahow, Eric E. 2004., Forecast of demand for chronic care nursing home services: 2005-2025, Doktora Tezi, Brandeis University, Waltham Massachusetts, USA.
- Calp, M. H., 2019. İşletmeler için personel yemek talep miktarının yapay sinir ağları kullanılarak tahmin edilmesi, Politeknik Dergisi.
- Carlson, RL, Umble, M., 1980. Statistical demand functions for automobiles and their use for forecasting in an energy crisis. The Journal of Business, 53,2-10.
- Çam, A., 2018. Türkiye'nin Enerji Verimliliğinin Yapay Sinir Ağı ve ARDL Yaklaşımı ile Analizi Çukurova Üniversitesi, İİBF, 01330, Balcalı, Sarıçam, Adana.
- Çuhadar, M., Güngör, İ. ve Göksu, A. 2009., Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Analizi: Antalya iline Yönelik Bir Uygulama, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi.
- Denton, J. W., 1995. How good are neural networks for casual forecasting. The Journal of Business Forecasting Methods & Systems.
- Dereli, T., 2000. Toplam kalite yönetiminin ışığı altında yapay zekanın endüstriyel problemlerin çözümünde kullanımı, seminer notları. Gaziantep.
- Ergezer, H., Dikmen, M. ve Özdemir, E., 2003. Yapay sinir ağları ve tanıma sistemleri. PİVOLKA, 2 - 6, 14-17.
- Erkaymaz, H. ve Yaşar, Ö. 2011., Yapay Sinir Ağları İle Hava Sıcaklığı Tahmini, 5th International Computer & Instructional Technologies Symposium, Elazığ, Türkiye, Fırat Üniversitesi.
- Fan, S. ve Hyndman, R., J., 2012. Short-Term Load Forecasting Based On a Semi-Parametric Additive Model, IEEE Transactions On Power Systems, 27, 134- 141.

- Fildes, R., 2006. The forecasting journals and their contribution to forecasting research: Citation analysis and expert opinion||, International Journal of Forecasting, 22 – 3, 415 – 432.
- Freeman, J.A. ve Skapura, D.M., 1991. Neural networks algorithms, applications, and programming techniques. Addison-Wesley Publishing Company. USA.
- Fuente, D.A., 2004. Artificial neural networks, the tutorial. Universidad Politecnica de Madrid.
- Gavcar, E., Sen, S., ve Aytakin, A., 1999., Türkiye’de Kullanılan Kağıt- Karton Türlerinin Talep Tahminlerinin Belirlenmesi. Tr. Journal of Agriculture and Forestry, TÜB\_TAK, 23. 203-211.
- Griffiths, W.E., Newton, L.S. and O’Donnell, C. J., 2010. Predictive densities for models with stochastic regressors and inequality constraints: Forecasting local-area wheat yield, International Journal of Forecasting, 397–412.
- Grossberg, S., 1992. Neural networks and natural intelligence. Massachusetts Institute of Technology. USA.
- Gürgen vd., 2017. Bütanol-Diesel yakıtı kullanılan bir sıkıştırma ateşlemeli motorda motor performansı ve egzoz emisyonlarının yapay sinir ağı ile tahmini, Pamukkale Univ Muh Bilim Dergisi, 576-581.
- Hajirezaie, M., Hussein, Seyyed, Barfouroush, Ahmad and Karimi, B. 2010., Modeling and evaluating the strategic effects of improvement programs on the manufacturing performance using neural Networks, African Journal of Business Management, 414-424.
- Hamzaçebi, C. ve Kutay, F., 2004. Yapay sinir ağı ile Türkiye elektrik enerjisi tüketiminin 2010 yılına kadar tahmini, Gazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi, 19, 227-233.
- Hamzaçebi, C., 2011. Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı, Ekin Yayınevi, Trabzon.
- Haykin, S., 1994. Neural networks, Maxwell-McMillan, Ontario-Canada.
- Hsu, L.C., 2003. Applying the grey prediction model to the global integrated circuit industry, Technological Forecasting & Social Change, 563–574.
- Hu, C., 2002., Advanced Tourism Demand Forecasting: ANN and Box-Jenkins Modelling, Doktora Tezi, Purdue University, MI, USA.
- İnsel, İ., 2010. A comparative analysis of the ARMA and neural network models: A case Turkish economy, İktisat İşletme ve Finans, 35-64.

- Jones, S. 2008., Measuring, Modeling, and Forecasting Demand in The Emergency Department, Doktora Tezi, The University of Utah, USA.
- Kauffman, N. L. ve Sopariwala, P. R., 1995., Market Share And Market Size Variances In A Multi-Product Environment: An Evaluation Of Competing Formulations, Journal Of Accounting Education, 463- 478.
- Kırbaşı, İ., 2018. İstatistiksel metotlar ve yapay sinir ağıları kullanarak kısa dönem çok adımlı rüzgâr hızı tahmini, Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi.
- Kıyıldı, R., 2017. Türkiye için Yapay Sinir Ağları Yöntemi ile Trafik Kazası Tahmini Araştırması, Mühendislik Fakültesi İnşaat Mühendisliği Bölümü, Niğde Ömer Halisdemir Üniversitesi, Türkiye.
- Kobu B., 1984. Üretim yönetimi. İ.Ü. İşletme Fakültesi, İstanbul.
- Kobu, B. 1994. Üretim Yönetimi, Avcıol Basım-Yayımlar, 8. Baskı, İstanbul.
- Koçak C., 2019. Karakurt H. B. "Yapay sinir ağları ile kablosuz yerel alan ağlarında veri trafiği optimizasyonu", Politeknik Dergisi.
- Kröse, B. ve Smagt, P.V., 1996. An introduction to neural networks. The University of Amsterdam. Amsterdam.
- Lin, C.T. ve Hsu, P.F., 2002. Forecast of nonalcoholic beverage sales in Taiwan using the grey theory, Asia Pacific Journal of Marketing and Logistics, 14, 3-12.
- Lin, C.T. ve Yang, S.Y., 2003. Forecast of the output value of Taiwan's optoelectronics industry using the grey forecasting model, Technological Forecasting and Social Change, 70, 177-186.
- Lin, C.T. ve Yang, S.Y., 2004. Forecast of the output value of Taiwan's IC Industry Using the Grey Forecasting Model, International Journal Computer Applications in Technology, 19, 23-27.
- Majhi, B. vd., 2015. Neurocomputing 167, 502-511.
- Moturi, C.A. and Kioko, F.K., 2013. "Use of artificial neural networks for short-term electricity load forecasting of Kenya national grid power system." International Journal of Computer Application, 63, 25-30.
- Matuyama, K., Sumita, T. ve Wakayama, D., 2009. Periodic forecast and feedback to maintain target inventory level, International Journal of Production Economics, 118-1, 298-304.
- Murray, G., 2003. Artificial neural networks.

- Müller, B. ve Reinhardt, J., 1990. Neural networks an introduction. Springer-Verlag, Berlin Heidelberg.
- Özcan, B., 2007. Yapay Sinir Ağı Yaklaşımıyla, Peçete Makinesi İmalatı Yapan İşletmede Makine İşleme Sürelerinin Tahmin Edilmesi, Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli.
- Öztemel, E., 2012. Yapay Sinir Ağları, 3. Baskı, Papatya Yayıncılık, İstanbul.
- Pankaj, M., Benjamin, W., 1992. "Élf-Improving Reactive Agents Based on Reinforcement Learning, Planning, and Teaching," Machine Learning, 8 Kluwer Academic Publishers, Boston, MA.
- Pirim, 2006. Artificial Neural Networks using monthly data of Manufacturing Industry Production Index.
- Serttaş, Z., 2011 Türkiye' de Perakende Sektöründe Talebi Etkileyen Etmenler ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Shamseldin, Asaad Y., 2010. Artificial neural network model for river flow forecasting in a developing country, Journal of Hydro informatics, 12 -1, 2235.
- Smith, L., 2003. An introduction to neural networks.
- Su, C. ve Cheng, C., 2016. A Hybrid Fuzzy Time Series Model Based On ANFIS.
- Şahin, M., 2013. Yapay Sinir Ağları ile Aydınlik Kalitesi Kontrolü, Afyon Kocatepe Üniversitesi Makalesi, Elektrik Eğitimi, Afyon.
- Şahin, A.E., 2018. Crypto Money Bitcoin: Price Estimation with ARIMA and Artificial Neural Networks.
- Şentürk, Z. vd., 2016. Yapay Sinir Ağları İle Göğüs Kanseri Tahmini, El-Cezerî Fen ve Mühendislik Dergisi.
- Tebo, A., 1994. Artificial neural networks: a developing science.
- Tekin, M., 2009. Üretim Yönetimi, Günay Ofset, Konya.
- Tekin, M., 1996. Üretim Yönetimi, Arı Ofset Matbaacılık, Konya.
- Thall, N., 1992. Neural Forecasts: A Retail Sales Booster, Discount Merchandiser, 32, p. 41.

- Türk, E., 2019. Yapay Sinir Ağları ile Talep Tahmini Yapma: Beyaz Eşya Üretim Planlaması için YSA Uygulaması, İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi.
- Utkun, E., 2014. Pamukkale Üniversitesi, Moda ve Tasarımı Programı, Buldan Meslek Yüksekokulu, Pamukkale Üniversitesi, Denizli, Türkiye.
- Var, H. ve Türkay, E., 2014. Yapay Sinir Ağları Kullanılarak Kısa Dönem Elektrik Yükü Tahmini, Eleco 2014 Elektrik - Elektronik - Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu, Kasım, Bursa, Bildiriler Kitabı: 23-27.
- Veelenturf, L.P.J., 1995. Analysis and applications of artificial neural networks. Prentice Hall International (UK) Limited. United Kingdom.
- Wei, L. Y., 2013. A Hybrid Model Based On ANFIS And Adaptive Expectation Genetic Algorithm To Forecast TAIEX, Economic Modelling, 33, 893-899.
- Wong, B., Thomas A, Selvi, Y., 1997. Neural network applications in business: A review and analysis of the literature, Decision Support Systems 19, 301-320.
- Yazıcı, M., 2018. Kredi Risk Analizlerinde Diskriminant Analizi, Lojistik Regresyon ve Yapay Sinir Ağlarının Karşılaştırılması, Esenyurt Üniversitesi İşletme ve Yönetim Bilimleri Fakültesi.
- Yurtoğlu, H., 2005. YSA Metodolojisi ile Öngörü Modellemesi.
- Zhang G., Patuwo B.E., Hu M.Y., 1998. Forecasting with artificial neural networks, International Journal Of Forecasting, 14-1, 35-62.
- Zhang, Y., Xu, H. ve Zheng, Y., 2012. Chinese residents' cold chain logistics demand forecasting based on GM 1,1 model, African Journal of Business Management, 6-14, 5136-5141.
- ZhoumcMahon, S.L, Walton, T.A., Lewis, A., 2002. Forecasting operational demand for an urban water supply zone. Journal of Hydrology, 259-1, 189-202.



## ÖZGEÇMİŞ

Adı Soyadı : Didem VURAL  
Doğum Yeri ve Yılı : İSTANBUL, 09/09/1993  
Medeni Hali : Bekar  
Yabancı Dili : İngilizce  
E-posta : didemvurall@gmail.com



### Eğitim Durumu

Lise :Çağrıbey Anadolu Lisesi, 2011  
Lisans :İstanbul Ticaret Üniversitesi, Mühendislik ve Tasarım Fakültesi, Endüstri Mühendisliği Bölümü, 2016  
Yüksek Lisans :İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, 2019

### Mesleki Deneyim

Kredi Analisti,  
Volvo Financial Services 2016-2017  
Stok Planlama Uzman Yardımcısı,  
Teknosa İç ve Dış Ticaret A.Ş. 2017-2018  
Kategori Uzmanı,  
Teknosa İç ve Dış Ticaret A.Ş. 2018-2019  
Kategori Uzmanı,  
Trendyol.com 2019-devam ediyor

### Yayınları

Ayvaz, B., Vural, D., 2019. Türkiye’de Perakende Sektöründe Elektronik Ürünlere Olan Talebin Yapay Sinir Ağı İle Modellenmesi. İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, 2019.