

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YAPAY SİNİR AĞLARI İLE ÜRÜN SATIŞ
MİKTARLARININ TAHMİNİ: MOBİLYA
SEKTÖRÜNDE BİR UYGULAMA**

YÜKSEK LİSANS TEZİ

Burçin SALTÖRÖK

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ
Enstitü Bilim Dalı : MÜHENDİSLİK YÖNETİMİ
Tez Danışmanı : Doç. Dr. Alparslan Serhat DEMİR

Temmuz 2022

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YAPAY SİNİR AĞLARI İLE ÜRÜN SATIŞ
MİKTARLARININ TAHMİNİ: MOBİLYA
SEKTÖRÜNDE BİR UYGULAMA**

YÜKSEK LİSANS TEZİ

Burçin SALTÖRÖK

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Enstitü Bilim Dalı : MÜHENDİSLİK YÖNETİMİ

Bu tez 22.07.2022 tarihinde aşğıdaki jüri tarafından oybirliğı / oyçokluğu ile kabul edilmiştir.

Jüri Başkanı

Üye

Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Burçin SALTÜRK

22.07.2022

TEŐEKKÜR

Çalıőmalarım boyunca bilgi, birikim ve tecrübeleri ile bana sürekli destek olan deęerli hocam Doç. Dr. Alparslan Serhat DEMİR'e teőekkürü bir borç bilirim.

Destekleriyle beni hiç yalnız bırakmayan aileme de sonsuz teőekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	v
ŞEKİLLER LİSTESİ	viii
TABLOLAR LİSTESİ.....	viii
ÖZET.....	x
SUMMARY	x
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
KAYNAK ARAŞTIRMASI	3
BÖLÜM 3.	
TALEP TAHMİNİ.....	10
3.1. Talep Tahmini Kavramı	10
3.2. Talep Tahmini Aşamaları	11
3.3. Talep Tahmini Çeşitleri.....	12
3.4. Talep Tahmin Yöntemleri	12
3.4.1. Kalitatif tahmin yöntemleri	12
3.4.1.1. Delphi metodu	13
3.4.1.2. Pazar araştırması yöntemi	13
3.4.1.3. Satış grupları yöntemi	13

3.4.1.4. Yönetici görüşleri yöntemi.....	14
3.4.1.5. Tarihi bilgi yöntemi.....	14
3.4.2. Kantitatif tahmin yöntemleri	14
3.4.2.1. Zaman serileri analizi	14
3.4.2.2. Nedensel yöntemler	18
3.4.2.3. Yapay zeka çözümlü yöntemler	19

BÖLÜM 4.

YAPAY SİNİR AĞLARI	21
4.1. Yapay Sinir Ağlarının Tanımı.....	21
4.2. Yapay Sinir Ağlarının Tarihçesi	21
4.3. Yapay Sinir Ağlarının Genel Özellikleri.....	22
4.4. Yapay Sinir Ağlarının Dezavantajları	23
4.5. Yapay Sinir Ağlarının Yapısı	23
4.5.1. Biyolojik sinir hücreleri	23
4.5.2. Yapay sinir hücreleri	24
4.6. Yapay Sinir Ağlarının Sınıflandırılması	26
4.6.1. Yapay sinir ağlarının ağ modellerine göre sınıflandırılması.....	26
4.6.1.1. İleri beslemeli ağlar	27
4.6.1.2. Geri beslemeli ağlar.....	27
4.6.2. Yapay sinir ağlarının öğrenme yapısına göre sınıflandırılması .	28
4.6.2.1. Danışmanlı öğrenme.....	29
4.6.2.2. Danışmansız öğrenme	29
4.6.2.3. Destekleyici öğrenme	30
4.7. Yapay Sinir Ağlarında Öğrenme Kuralları	31
4.7.1. Hebb kuralı.....	31
4.7.2. Hopfield kuralı	31
4.7.3. Delta kuralı	31
4.7.4. Kohonen kuralı.....	32
4.8. Geri Yayılım Algoritması ve Çok Katmanlı Algılayıcılar	32
4.8.1. Çok katmanlı algılayıcılarda ileri besleme.....	33
4.8.2. Çok katmanlı algılayıcılarda geri besleme	33

4.8.3. Çok katmanlı algılayıcı ağı çalışma prosedürü	33
--	----

BÖLÜM 5.

TALEP TAHMİNİ UYGULAMASI	38
5.1. Talep Tahmini Probleminin Tanımlanması.....	38
5.2. Yapay Sinir Ağı Mimarisi	42
5.3. Yapay Sinir Ağı Matlab Uygulaması	42
5.3.1. Eğitim fonksiyonunun belirlenmesi	43
5.3.2. Nöron sayısının belirlenmesi.....	45
5.3.3. Aktivasyon fonksiyonunun belirlenmesi.....	48
5.3.4. Çevrim sayısının belirlenmesi.....	49
5.3.5. Maksimum doğrulama hatasının belirlenmesi	50
5.3.6. Ağ türünün belirlenmesi.....	52
5.4. Yapay Sinir Ağı'nın Eğitilmesi	53
5.5. Sonuçların Test Edilmesi	58

BÖLÜM 6.

SONUÇ VE DEĞERLENDİRME	60
KAYNAKLAR	62
ÖZGEÇMİŞ	65

SİMGELER VE KISALTMALAR LİSTESİ

ADALINE	: Adaptif doğrusal eleman
ANFIS	: Uyarlamalı sinirsel bulanık çıkarım sistemi
ÇKA	: Çok katmanlı algılayıcılar
EGE	: Ekonomi güven endeksi
ELM	: Aşırı öğrenme makinesi
EPOCH	: Çevrim sayısı
GSYİH	: Gayri safi yurtiçi hasıla
HMDB	: Hane halkı maddi durum beklentisi
LOGSIG	: Logaritmik sigmoid transfer fonksiyonu
MAD	: Ortalama mutlak sapma
MADALINE	: Çoklu adaptif doğrusal eleman
MAE	: Ortalama mutlak hata
MAPE	: Ortalama mutlak yüzde hata
MAX_FAIL	: Maksimum doğrulama hatası
MSE	: Ortalama Hata Kareleri
MLP	: Çok katmanlı algılayıcı
NARX	: Doğrusal olmayan dışsal girdili otoregresif ağ
RKGE	: Reel kesim güven endeksi
RMSE	: Hata kareleri ortalamasının karekökü
RNN	: Tekrarlayan sinir ağı
SÜE	: Sanayi üretim endeksi
TANSIG	: Tanjant sigmoid transfer fonksiyonu
TGE	: Tüketici güven endeksi
TÜFE	: Tüketici fiyat endeksi
TÜİK	: Türkiye istatistik kurumu

ÜFE : Üretici fiyat endeksi
YH : Yatırım harcamaları
YSA : Yapay sinir ağları

ŞEKİLLER LİSTESİ

Şekil 4.1. Biyolojik bir sinir hücresi (Kriesel, 2007)	24
Şekil 4.2. Yapay sinir hücresi (Kurt, et al., 2017).....	24
Şekil 4.3. Yapay sinir ağı (Akpınar, 2017)	26
Şekil 4.4. İleri beslemeli ağ yapısı (Öztürk & Şahin, 2018)	27
Şekil 4.5. Geri beslemeli ağ yapısı (Kurnaz, 2014)	28
Şekil 4.6. Danışmanlı öğrenme algoritması (Korkut, 2019).....	29
Şekil 4.7. Danışmansız öğrenme algoritması (Kargı & Öztürk, 2013).....	30
Şekil 4.8. Destekleyici öğrenme algoritması (Aydın , 2012).....	30
Şekil 4.9. ÇKA'nın yapısı (Doğan, 2019)	32

TABLULAR LİSTESİ

Tablo 5.1. ÜrünA1 için eğitim fonksiyonunun belirlenmesi	43
Tablo 5.2. ÜrünA2 için eğitim fonksiyonunun belirlenmesi	44
Tablo 5.3. ÜrünA3 için eğitim fonksiyonunun belirlenmesi	44
Tablo 5.4. ÜrünA1 için nöron sayısının belirlenmesi	45
Tablo 5.5. ÜrünA2 için nöron sayısının belirlenmesi	46
Tablo 5.6. ÜrünA3 için nöron sayısının belirlenmesi	47
Tablo 5.7. ÜrünA1 için aktivasyon fonksiyonunun belirlenmesi	48
Tablo 5.8. ÜrünA2 için aktivasyon fonksiyonunun belirlenmesi	48
Tablo 5.9. ÜrünA3 için aktivasyon fonksiyonunun belirlenmesi	49
Tablo 5.10. ÜrünA1 için çevrim sayısının belirlenmesi	49
Tablo 5.11. ÜrünA2 için çevrim sayısının belirlenmesi	50
Tablo 5.12. ÜrünA3 için çevrim sayısının belirlenmesi	50
Tablo 5.13. ÜrünA1 için maksimum doğrulama hatasının belirlenmesi	51
Tablo 5.14. ÜrünA2 için maksimum doğrulama hatasının belirlenmesi	51
Tablo 5.15. ÜrünA3 için maksimum doğrulama hatasının belirlenmesi	52
Tablo 5.16. Ürünlerin en uygun parametre değerleri	53
Tablo 5.17. YSA sonuçları	59
Tablo 5.18. Korelasyon katsayısı sınıfları (Şen, 2017)	59

ÖZET

Anahtar kelimeler: Talep tahmini, yapay sinir ađları, yatak ve kanepeler mekanizması, mobilya sektörü

İşletmelerin müşteri taleplerine doğru zaman ve miktarda cevap verebilmeleri için talep tahmini çalışmalarına önem vermeleri gerekmektedir. Hangi üründen ne kadar üretilmesi gerektiğini yüksek doğrulukla tahmin edilmesi müşteri memnuniyetini arttırıp, işletmelerin pazarda daha iyi bir yer edinmelerini ve devamlılıklarını sağlamalarına yardımcı olacaktır.

Bu çalışmada günümüzde sıkça kullanılan yapay zekâ tekniklerinden biri olan Yapay Sinir Ağları (YSA) ile mobilya sektöründe faaliyet gösteren bir firmada talep tahmini uygulaması yapılmıştır. Firmada ABC analizi yapılarak kıymetçe en çok tüketilen bileşenlerden olan yatak ve kanepeler mekanizmaları için satış tahminleri yapılmıştır.

Mekanizma satış miktarını etkileyen girdi faktörleri olarak; mobilya sektörü sanayi üretim endeksi, dolar kuru ve fiyat değişimi kriterlerinin satış miktarını etkiledikleri belirlenmiştir. Matlab Programı'nda oluşturulan ađ ile sonraki yıla ait satış miktarları tahmin edilmiştir. Elde edilen sonuçlar YSA tekniğinin yüksek doğrulukta tahminler elde edebileceğini göstermektedir.

FORECASTING PRODUCT SALES AMOUNTS BY ARTIFICIAL NEURAL NETWORK: AN APPLICATION IN THE FURNITURE INDUSTRY

SUMMARY

Keywords: Demand forecasting, neural networks, bed and sofa mechanism, furniture industry

In order for businesses to respond to customer demands in the right time and amount, they need to give importance to demand forecasting studies. Predicting how much of each product should be produced with high accuracy will increase customer satisfaction and help businesses gain a better place in the market and ensure their continuity.

In this study, a demand forecasting application was made in a company operating in the furniture industry with Artificial Neural Networks (ANN), which is one of the frequently used artificial intelligence techniques. ABC analysis was performed in the company, and sales forecasts were made for bed and sofa mechanisms, which are among the most consumed components by value.

As the input factors affecting the sales amount of the mechanism; It has been determined that the furniture industry industrial production index, dollar rate and price change criteria affect the sales amount. With the network created in the Matlab Program, the sales amounts for the next year were estimated. The obtained results show that the ANN technique can obtain highly accurate predictions.

BÖLÜM 1. GİRİŞ

Günümüzde artan rekabet ile işletmeler, sürekli değişimle karşı karşıya kalmaktadır. Bu değişime ayak uydurabilmeleri ve sürdürülebilirliklerini sağlamak için önceden tedbirlerini alıp değişimler karşısında nasıl bir yol izleyeceklerini belirlemeleri gerekmektedir. Hızlı talep değişimleri ve fiyatlardaki değişimler; artan rekabet, ekonomik değişimler, sürekli değişen tüketici tercihleri, teknolojik değişimler gibi faktörler sebebiyle artmaktadır. Bu sebeple işletmeler, bu değişimleri hızlı ve doğru bir şekilde çözüm üreterek ilerlemek ve müşteri taleplerini önceden belirleyebilmek için yeni yöntemler kullanmaya yönelmişlerdir.

Talep tahmini; işletmelerin, tüketicilerin kararlarındaki değişimlere hızlı bir şekilde cevap verebilmesi için önemli rol oynamaktadır. Artan rekabet ile ayakta kalabilmek için işletmenin, tüketicilerin talep ettiği ürünü, istenilen zamanda karşılayabilmek için tahmin çalışmalarına önem verilmiştir. Bunun için hammadde, makine, insan gücü ve yatırımların belirlenmesindeki en önemli faktör talep tahminidir.

Talep tahmin yöntemleri, “kalitatif” ve “kantitatif” olmak üzere ikiye ayrılmaktadır. Kalitatif tahmin yöntemleri, daha çok tecrübe ve uzman görüşlerine dayanmaktadır. Kantitatif tahmin yöntemleri ise verilerle çeşitli matematiksel modellere ve istatistiksel çözümlere dayanır. Günümüzde en yaygın olarak kullanılan yöntem yapay zeka tabanlı yapay sinir ağları ile yapılan tahmin yöntemidir. Bu yöntem, geçmiş veriler ile talebi etkileyen değişkenler arasında bir ilişki kurarak gelecek için güçlü bir tahmin yapılmasını sağlamaktadır.

Mobilya sektörü, dünya ekonomisinde önemli role sahip sektörlerden biridir. Bu sektör içerisinde ayakta kalıp gelişebilmek için talep tahminlerinin başarılı bir

şekilde yapılması gerekmektedir. Tüketici taleplerinin istenilen zamanda karşılanması için, gelecek pazarın tespiti, satış değerlerinin ve ürün değişimlerinin ne olacağının tespiti için firmanın üretim kaynaklarını planlanması gerekmektedir.

Bu tez çalışmasının ikinci bölümünde talep tahmini ile ilgili literatür taraması yapılmıştır. Üçüncü bölümde ise talep tahmini tanımı, çeşitleri ve yöntemlerinden bahsedilmiştir. Dördüncü bölümde ise günümüzde en yaygın kullanılan ve talep tahmin yöntemi olan yapay sinir ağları ile tahmin yöntemi açıklanmıştır. Yapay sinir ağlarının tarihçesi, avantajları, oluşturulması ve prensipleri anlatılmıştır.

Çalışmanın son bölümünde ise Türkiye’de mekanizma üretimi yapan bir işletmede satış miktarları tahmin edilmeye çalışılmıştır. İşletmede ABC analizi yapılarak satış hasılası açısından önem taşıyan ilk üç ürün tespit edilmiştir. Bu ürünlerin satış miktarlarını etkileyen değişkenler belirlenerek yapay sinir ağları modelleri kurulmuştur. Modellerin eğitim süreçlerinde en uygun parametreleri belirlenerek daha sonra test için gelecek satış tahmini yapılarak sonuçları incelenmiştir.

BÖLÜM 2. KAYNAK ARAŞTIRMASI

Gelecekte olacakları öngörebilmek ve buna göre pozisyon almak, firmalar açısından önemli olduğu gibi uluslararası ekonomiler açısından da son derece önemli hale gelmiştir. Firmalar, hızla dijitalleşen dünyaya ayak uydurabilmek adına teknolojinin tüm imkanlarından faydalanmak istemektedir. Yapay zekâ ve makine öğrenmesi teknolojilerini, veri analizi ve talep tahmini için kullanan firmalar, öngörü kabiliyetini güçlendirerek riskleri minimuma indirmenin karşılığını verimlilik olarak almaktadırlar.

Geçmişten günümüze kadar birçok alanda bilimsel araştırmalar yapılmaktadır. Birçok talep tahmin yöntemleri olmasına rağmen, bu yöntemlerin o işletme koşullarına göre en iyi olanın belirlenmesi gerekmektedir. Bu çalışmada güncel uygulamaları göstermek için 2013 yılı ve sonrasında yayınlanan çalışmalar incelenmiştir. Literatürde incelenen mobilya sektörüne ve diğer sektörlere ait talep tahmini çalışmaları aşağıda özetlenmiştir:

Mahbub, Paul ve Azeem (2013), bir mobilya şirketinde gerçekleştirdikleri çalışmada, aylık ürün talebini tahmin etmek için zaman, festival dönemi, promosyon programları, tatiller, reklam sayısı, reklam maliyeti, işçi sayısı gibi etkenleri talebi etkileyen faktörler olarak belirlemişler ve YSA tabanlı bir model geliştirerek Brown'ın çift düzleştirme tahmin modeli ile karşılaştırma yapmışlardır. Temmuz 2007-Ağustos 2010 yılları arasındaki 38 aylık verinin, 23 adetini eğitim için, 15 adetini test için kullanmışlardır. Çok katmanlı ileri beslemeli YSA modelinin MAPE değerinin, istatistiksel doğrusal modele göre oldukça düşük olduğunu gözlemlemişlerdir. Geliştirilen algoritmanın, birçok faktörü hesaba kattığı için daha iyi olduğu sonucuna ulaşmışlardır (Mahbub, et al., 2013).

Hazır, Koç ve Esnaf (2015), Matlab’da YSA yöntemi ve regresyon analizi yöntemi ile 2023 yılı Türkiye mobilya talebini tahmin ettikleri çalışmada, 2004-2013 yılları arasındaki girdi verileri olarak; gayri safi yurtiçi hasıla (GSYİH), tüketici güven endeksi (TGE), reel kesim güven endeksi (RKGE), yatırım harcamaları (YH), nüfus konut satış değerleri, dolar para birimini seçmişlerdir. Verilerin %80’ini eğitim, %20’si test için kullanmışlardır. Performans ölçütü olarak RMSE’yi (Hata Kareleri Ortalamasının Karekökü) dikkate almışlardır. Gelecek 10 yılın girdi değerleri için lineer trend model kullanılarak Minitab Yazılımı ile tahmin yapmışlardır. Yapay sinir ağlarının, regresyon analizine göre daha iyi sonuç verdiği kanıtlamışlardır (Hazır, et al., 2015).

Yücesan, Gül ve Çelik (2017), yapmış oldukları çalışmada, girdi verileri olarak TGE, ÜFE, ilgili aydaki tatil günleri sayısını kullanarak 2009-2015 yılları arasındaki 84 aylık veriler ile Bayes kuralları eğitimine dayalı YSA modeli oluşturarak bir mobilya fabrikasına ait genç odası, yatak odası, yemek odası, oturma grubu ve koltukların aylık satışlarını tahmin etmişlerdir. Elde ettikleri sonuçlara göre, Bayes kuralları eğitimine dayalı YSA modelinin kullanılmasının, mobilya fabrikasının aylık satışlarını tahmin etmek için uygun bir seçim olduğunu gözlemlemişlerdir (Yücesan, et al., 2017).

Yücesan, Gül ve Çelik (2018), yapmış oldukları çalışmada, 2009-2015 yılları arasındaki 84 aylık verileri kullanarak YSA, ARIMAX ve YSA-ARIMAX hibridizasyonu ile bir mobilya fabrikasının yemek odası, yatak odası, genç odası, oturma grubu, koltuk ürünlerinin satışını tahmin etmişlerdir. Elde ettikleri sonuçlara göre, YSA-ARIMAX hibrit modelinin daha iyi bir tahmin doğruluğu sağladığını gözlemlemişlerdir (Yücesan, et al., 2018).

İmren, Kaygın ve Karayılmazlar (2021), Türkiye’deki mobilya sektörünün ithalat ve ihracatının 2014-2028 yıllarındaki değişimini, YSA kullanarak tahmin etmişlerdir. Çalışma verileri olarak 1969-2018 yıllarına ait Türkiye mobilya sektörü dış ticaret değerlerinden yararlanmışlardır. Verilen %70’ini eğitim, %15’ini doğrulama, %15’ini test için kullanmışlardır. Girdi değerleri olarak lif levha, yonga levha, odun

temelli panel ve endüstriyel odun mantarları, GSYİH, döviz kuru, TÜFE, nüfus ve ekonomik büyümeyi seçmişlerdir. Tahmin sonucunda tahmin değerlerinde artış olduğunu gözlemlemişlerdir (İmren, et al., 2021).

Sarı (2016), yapmış olduğu çalışmada, otomotiv yan sanayi ürünlerinden biri olan motor yataklarının satış talebini etkileyen faktörler olarak; dolar kuru, GSYİH, araç parkı sayısı, üretilen araç sayısı, ihracat sayısı, faiz oranı, TÜFE, ÜFE olarak belirlemiş ve YSA, çoklu regresyon yöntemi, zaman serileri analizi yöntemleriyle talep tahmini çalışması yapmıştır. YSA için Matlab Programı, regresyon analizi için Excel, zaman serileri analizi için Minitab kullanmıştır. Performans ölçütü olarak MAPE, MAD ve MSE değerlerini dikkate almıştır. Çalışmayı, 2004-2014 yılları arasındaki veriler ile yapmıştır. 95 adet veri, eğitim; 36 adet veri, test için kullanılmıştır. En iyi tahmin sonucunun YSA tekniği ile yapılan model olduğunu gözlemlemiştir (Sarı, 2016).

Yangın ve Zontul (2017), yaptıkları çalışmada, eğitim sektöründe satış tahmini yapmak için, girdi verileri olarak; satış hacmi, öğrenci sayısı, hane eğitim harcaması, dolar kuru, müşteri sayısı, TÜFE ve ÜFE'yi kullanarak Yapay Sinir Ağları (YSA) modeline bir örnek sunmuşlardır. Çalışmada bir firmanın verilerinden yararlanarak Matlab R2008A Programı'nın Neural Network uygulamasını kullanmışlardır. Çalışmada 2010 ve 2015 yılları arasında il bazlı satış verilerini, tutar cinsinden vermişlerdir. Tahmin değerlerini başarılı bir şekilde elde etmişlerdir (Yangın & Zontul, 2017).

Kurt, Karayılmazlar, İmren ve Çabuk (2017), yapmış oldukları çalışmada, Türkiye kâğıt-karton sanayisinin ihracat satış rakamlarını YSA ile tahmin etmek için girdi verileri olarak; Türkiye kâğıt-karton üretimi, atık kâğıt, endüstriyel odun, tomruk üretimi, nüfus, GSYİH, TÜFE, ÜFE, döviz kurları ve ekonomik büyüme rakamlarını kullanmışlardır. Verileri normalizasyon işleminden geçirmişlerdir. 1990 ve 2015 yılları arasındaki verilerin %70'ini eğitim, %15'ini doğrulama, %15'ini test için kullanarak, Matlab Programı'nda ağ oluşturmuşlardır. Performans ölçütü olarak

MSE'yi belirleyerek, YSA ile yapılan tahminde başarılı bir sonuç elde etmişlerdir (Kurt, et al., 2017).

Eren ve Satoğlu (2017), giyim sektöründe bir firmanın ürünlerine yönelik satış tahmini için iki tip YSA modeli oluşturmuşlardır. Mevsimselliğin dikkate alındığı ve alınmadığı bu çalışmalarda hava sıcaklığı, indirim, müşteri sayısı verilerini, girdi verileri olarak düşünmüşlerdir. Seçmiş oldukları ürünlerden biri mevsimsel talep karakteristiğine sahip olan t-shirt, diğeri ise mevsimsel talebi olmayan spor ayakkabısıdır. Birimleri arasında farklılık olduğu için normalizasyon çalışması yapılan 36 aylık verinin, Matlab yazılımında Levenberg-Marquardt Öğrenme Algoritması ile %70'ini eğitim, %15'ini doğrulama, %15'ini test için kullanmışlardır. T-shirt için zaman serisi YSA modelini kurmuşlardır. Performans ölçütü olarak MSE değeri tek başına yeterli olmadığı için regresyon katsayısını da hesaplamışlardır ve başarılı da olmuşlardır. Spor ayakkabısı için zaman serisi YSA ile talep tahmininin uygun teknik olmadığını görmüşlerdir. Regresyon katsayısı ile YSA'nın uygun sonuç verdiğini gözlemlemişlerdir (Eren & Satoğlu, 2017).

Calp (2019), yapmış olduğu çalışmada, 110 kişilik bir personel kapasitesine sahip bir işletmenin 2016 ve 2018 yılları arasındaki verileri ile YSA kullanarak günlük personel yemek talebini tahmin etmiştir. Matlab Programı'nda oluşturulmuş olan modelin girdi verilerini; çorba, ana yemek, ek yemek, ek yardımcı yemek, içecek, haftanın günü, resmî tatil, mevsim olarak belirlemiştir. 550 adet gerçek verinin %70'lik kısmını eğitim, %30'luk kısmını ise test için kullanmıştır. Sonuçlar ile modelin oldukça iyi olduğunu kanıtlamıştır (Calp, 2019).

Türk ve Kiani (2019), yaptıkları çalışmada, girdi verileri olarak tüketici güven endeksi (TGE), reel kesim güven endeksi (RKGE), gayri safi yurtiçi hasıla (GSYİH), sanayi üretim endeksi (SÜE), tüketim harcamaları (TH), hane halkı maddi durum beklentisi (HMDB), ekonomi güven endeksi (EGE), evlenme istatistiklerini kullanarak 2016-2017 yılları arasındaki Türkiye'deki beyaz eşya satışlarını yapay sinir ağı ve çok değişkenli regresyon analizi ile tahmin etmişlerdir. TÜİK'in web sitesinden aldıkları veri setlerinde normalizasyon işlemi yapmışlardır. Bu çalışmada

Matlab Programı'ndan yararlanarak ileri beslemeli geri yayımlı yapay sinir ağı modeli oluşturmuşlardır. Performans ölçütü olarak ise YSA ile elde edilen MSE değerini ve çok değişkenli regresyon analizi ile elde edilen MSE değerini karşılaştırmışlardır. YSA'nın gerçek değerlere daha yakın bir sonuç ortaya çıkardığını kanıtlamışlardır (Türk & Kiani, 2019).

Yanık (2019), iş makineleri yedek parçaları üreten bir tesis için YSA ve çoklu regresyon analizini kullanarak yapmış olduğu çalışmada, 2010-2018 yılları arasındaki 108 aya ait girdi verileri olarak; dünyada satılan iş makinası sayısı, yıllara ve aylara göre dolar kuru ve aylık etki oranını kullanmıştır. Uygulamada Matlab R2016a yazılımı ve performans için MAPE kullanmıştır. İleri beslemeli geri yayılım algoritması ile 108 adet verinin 96 adeti eğitim için, 12 adeti ise test için seçmiştir. İki model arasında karşılaştırılma yapıldığında YSA'nın tahmin performansının üstün olduğunu gözlemlemiştir (Yanık, 2019).

Abellatief, Shaaban ve Abu-Raya (2019), Mısır hükümeti tarafından son zamanlarda büyük ilgi gören, önemli ve değerli bir yere sahip olan en büyük otomobil şirketinin satış tahminini yapmış oldukları çalışmada girdi verileri olarak; birim satış fiyatı, enflasyon oranı, GSYİH, yakıt fiyatı, döviz kuru, satış sipariş tarihini kullanmışlardır. YSA, MLR, ANFIS modelleri ile Şubat 2015- Mart 2018 yılları arasındaki verilerin %85'ini eğitim, %15'ini test için kullanarak karşılaştırma yapmışlardır. En çok satılan ve gelecekte de satışının devam etmesine karar verilen bir araç modeline göre tahmin çalışması yapmışlardır. Birden fazla fiyata satılan araçların ortalama fiyatını almışlardır. Modeli önce yapay sinir ağı, devamında çoklu regresyon tekniği, sonrasında ise ANFIS ile eğitmişlerdir. Ağın eğitiminde Levenberg-Marquart Algoritması ve performans ölçütü olarak RMSE ve R^2 kullanmışlardır. Yazılım olarak Matlab programı tercih edilerek, YSA'nın diğerlerine göre daha iyi bir sonuç verdiğini gözlemlemiştirler (Abellatief, et al., 2019).

Topal (2019), yapmış olduğu çalışmada, YSA kullanarak Bayesian Regülasyon geri yayılım yöntemiyle bir otomobil markasının (Volkswagen) satış miktarının tahmin

etmiştir. İşletmeye ait Facebook marka sayfasından 2012-2017 yılları arasındaki 2267 adet gönderiye ait olan beğenme, yorum ve paylaşma verilerini Facebook Graph API ile almıştır. Satış verilerini Otomotiv Distribütörleri Derneğinin web sitesinden, arama motoru verilerini ise Google Trends'den almıştır. Girdi verileri olarak ay bilgisi, gönderi sayısı, beğenme, yorum, paylaşım, arama verilerini, performans ölçütü olarak ise MSE, MAPE, R değerlerini değerlendirmiştir. Tüketicilerin kişisel verilerini kullanmadan başarılı bir tahmin çalışması yapmıştır (Topal, 2019).

Amalnick, Habibifar, Hamid (2020), ilaç endüstrisindeki talep tahmini çalışmasında, veriler üzerinde yapmış oldukları kümeleme ve sınıflandırma işlemi sayesinde hatanın azaldığını görmüşlerdir. Bunlar için K- Means ve Karar Ağacı yöntemlerini kullanmışlardır. Performans ölçütü olarak MAPE, AVR ve R değerlerini dikkate almışlardır. Girdi verileri olarak; ürün tipi, ürün kodu, üretim ayı, üretim sezonu, ürün yaş aralığı, ürünün hedef hastalığı, ürünün fiyatı, üretilen/ithal edilen ürün, münhasırlık, günlük tüketim sıklığı, ürünün hedef hastalık türü, reçeteli veya reçetesiz satılan ilaçlarını belirlemişlerdir. 43 çeşit ürüne ait 519 adet verinin %70'ini eğitim, %30'unu test için kullanılmışlardır. MLP sinir ağını ve Polinom sinir ağını Matlab'da uygulayarak yapmışlardır. Bu çalışma ile daha iyi bir üretim planlamasının yapılmasını ve hammadde siparişlerinde karar verilmesinde başarılı sonuçlar elde edilmesini sağlamışlardır (Amalnick, et al., 2020).

Lin, Cheng ve Chen (2021), yapmış oldukları çalışmada, Tayvan'da bir otoyoldaki servis istasyonunun verilerini kullanarak satış tahmini için YSA ve RNN arasında karşılaştırma yapmışlardır. Analiz için Tayvan hükümetinden 2018 yılına ait 4 veri setini (yıllık çalışma takvimi, gerçek zamanlı hava koşulları, otoyol trafik akış koşulları ve hizmet alanı satışları) olarak veriler üzerinde ana özellik çıkarma, boyut küçültme gibi analizler yapmışlardır. Özellik çıkarmayı Python kullanarak, boyut küçültmeyi Spss kullanarak, modellemeyi ise Matlab Neural Toolbox kullanarak gerçekleştirmişlerdir. Çalışmada sürecin tüm verileri veya sadece hafta içindeki verileri dikkate alındığında YSA'dan elde edilen RMSE, RNN'den elde edilen RMSE'den daha düşük olduğunu; fakat tatiller ve hafta sonları düşünüldüğünde

RNN'den elde edilen RMSE'nin daha düşük olduğunu gözlemlemişlerdir. Sonuç olarak, hafta içi satışlarını tahmin etmek için YSA'nın; tatillerdeki satışları tahmin etmek için RNN'nin daha iyi olduğunu kanıtlamışlardır. Bu çalışmada, satış tahmini için ağ seçiminin tarihlere göre belirlenmesi gerektiğini tavsiye etmişlerdir (Lin, et al., 2021).

Literatürdeki incelenen tahmin çalışmalarında genel olarak YSA'nın başarılı bir yöntem olduğu görülmüştür. Yapay sinir ağlarının veriler arasındaki ilişkiyi keşfetmede diğer yöntemlere göre daha üstün olduğu çalışmalarla ispatlanmıştır.

BÖLÜM 3. TALEP TAHMİNİ

3.1. Talep Tahmini Kavramı

Talep, tüketicinin istenilen zamanda bir ürünü satın almak istediği ürün miktarıdır. Kısacası, tüketicinin satın alma isteğidir. Talep tahmini, tüketicinin istediği ürünü ne zaman, ne kadar talep edeceğini önceden kestirmektir. Tahmin, akla ya da verilere dayanarak bir şeyi önceden kestirmektir. Talep tahmini; üretimin planlanmasında, kaynakların tedarik edilmesinde maliyet açısından işletmeler için önem kazanmaktadır. Bunun yanında yarı mamul kaynak stoklarının belirlenmesinde ve hammadde miktarlarının tespit edilmesinde de maliyet açısından önemlidir. Stok, işletmelerin ölü yatırımdır. Müşteri memnuniyeti sağlayarak istenilen ürünü, istenilen miktarda verebilmek için pazar payının önceden belirlenmesinde talep tahmini önemlidir. Müşteri, ürünü isteği zamanda alamazsa başka firma araştırmasına girecektir. İşletme içerisinde mesai saatleri, çalışan sayısı gibi hesaplamaların önceden yapılmasını sağlar. Satış tahmini, talep tahmininin bir sonucudur. Talep tahmin verileri; işletmelerde hammadde, insan gücü, yarı mamul, mamul stok, yatırım kararları için temel verilerdir. Ürünün pazardaki talebinin tahmin edilmesi, gelecekle ilgili bazı kararların alınması için önemlidir. Talep tahmininde, ürünlerin talebi karşılayamayacak noktaya gelmesi ya da satılmayan ürünlerle stok oluşması şeklinde hatalar olabilir.

Zaman aralığına göre talep tahminleri şu başlıklar halinde ele alınır (Yazıcıoğlu, 2010):

Çok kısa süreli tahminler: Günlük ya da haftalık yapılan tahminlerdir. Günlük üretim planlarının hazırlanması, stok kontrolünün sağlanması amacıyla yapılır.

Kısa süreli tahminler: Bir hafta ile altı ay arasındaki tahminlerdir. Üretim, sipariş ve tedarik zamanlarının tahminleri için yapılır. Böylelikle makine ve işgücü ayarlaması yapılmış olur.

Orta süreli tahminler: 6 ay ile 5 yıl arasındaki tahminlerdir. Mevsimsel olan ürünlerin talebinin stok planlaması için yapılır. Tedarik süresi belirsiz olan ya da uzun tedarik süresi gerektiren ürünler için yapılır.

Uzun süreli tahminler: 5 yıldan fazla yapılan tahminlerdir. Genellikle yeni yatırım planları, kapasite planlamaları, yeni tesis kararları ya da yeni makine alım kararları için yapılan tahmin çeşitleridir.

3.2. Talep Tahmini Aşamaları

Talep tahmini 5 adımda gerçekleştirilir. Bu adımlar (Kobu, 2008):

1. Talep tahmininde amacın belirlenmesi: Talep tahmininin neden ve hangi amaç için yapıldığı belirlenmelidir. Tahminin ne zaman yapılacağı, ne kadar detaylı olması gerektiği belirlenmelidir.
2. Talep tahmin zamanının belirlenmesi: Talep tahmininin zamanın doğru belirlenmesi, tahminin doğruluğunu artıracaktır. Seçilen doğru zaman aralığı ile daha güçlü bir talep tahmini mümkündür.
3. Bilgilerin toplanması: Talep tahmini için gerekli olan bilgiler tahmin konusunda doğruluğu arttıracaktır. Daha doğru, güvenilir tahmin için gerekli olan bilgiler toplanıp değerlendirilmelidir.
4. Tahmin yönteminin belirlenmesi ve hatanın hesaplanması: Tahmin amacı ile tahminde kullanılacak yöntemin seçilmesi, eldeki verilerle daha iyi belirlenecektir. Bu sayede kullanılacak en uygun yöntem belirlenmiş olur. Sonrasında ise gerçek

değerler ile tahmin yapılan değerler arasında kıyaslama yapılır. Ve bunun sonucunda tahmin hatası belirlenmiş olur. Gerçekleşen ile tahmin edilen değerler arasındaki fark da ortaya çıkar.

5. Tahmin sonuçlarının geçerliliğinin araştırılması: Gerçekleşen değerler ile tahmin değerleri arasındaki farkların oluşma sebeplerinin araştırılmasıdır.

3.3. Talep Tahmini Çeşitleri

Finansal tahmin, finansal konulardaki ihtiyaçlar belirlenerek gelecek için kar tahmini yapılır. 1 ile 2 ay arasındaki bütçe tahminleri yapmak için kullanılır. Satış tahmini, pazarlama ile ilgili kısa vadede yapılan stratejilerin planlanması için yapılır. Yapılacak olan promosyon, kampanya gibi konularda daha etkili doğru kararlar alabilmek için önemlidir. Üçer aylık yapılan tahminlerin daha etkili olduğu öngörülür. Üretim tahmini, ne zaman, ne kadar hangi üründen talep edileceğini tahmin etmek için yapılır. Kaynakların daha etkin kullanımı, üretimde alınacak kararların daha iyi ve verimli olması için önemlidir. Ayrıca işgücü planlaması ve kapasite planlarının oluşturulmasında daha iyi kararlar alabilmemizi sağlar. Pazar tahmini, 1 yıl ile 20 yıl arasındaki dönemi kapsayan büyüme planları ve araştırma geliştirme faaliyetlerinin tahmini için yapılır. Büyük önem arz etmektedir. Şirketin geleceğini belirleyen yolu tahmin etmek için önemle hazırlanması gereken bir tahmindir.

3.4. Talep Tahmin Yöntemleri

3.4.1. Kalitatif tahmin yöntemleri

Bir veya birden fazla kişinin belirli bir matematiksel model kullanmadan deneyimlerini, sezgilerini, düşüncelerini, katarak yapılan tahminlerdir. Sübjektiftir; bu nedenle tahmin sonuçları, tahmini yapan kişilere özgüdür ve her bir tahmincinin tahmini farklı olabilir. Uzun dönemli tahminler için daha çok kalitatif tahmin metotları tercih edilir. Bu yöntem, çevresel koşullar dikkate alınarak yapılan

tahmindir. Bu yüzden, verilere dayanmadığı için tahmin performansı düşüktür (Nasuhoglu, 2019).

3.4.1.1. Delphi metodu

1950'li yıllarda ABD'de RAND şirketindeki Olaf Helmer, Normon Dalkey tarafından uygulanmıştır. Tahminin belirlenmesi için karar verici kişi, kişiler bir arada olmaksızın uzmanlara sorular sorar. Bu sorulardan sonra oluşan cevaplar tekrar raporlanıp yeni sorular yöneltilir. Tahminler belli bir değere gelene kadar bu aşamalar tekrar edilir. İstenilen ve üzerinde uzlaşmış tahminler elde edilince durdurulur. Bu metodun avantajı, kişiler bir araya gelmediğinden çatışmalar azalır ve herkesin bilgisinden istifade edilir. Dezavantajı ise sistemin yavaş işlemesidir (Sarı, 2016).

3.4.1.2. Pazar araştırması yöntemi

Tüketicilerden telefonla arama, anket gibi yöntemlerle bilgi edinilerek talep tahmini yapılır. Pazar araştırmalarında en fazla anket yöntemi uygulanmaktadır. Yeni bir ürün için ya da mevcut ürün üzerindeki değişiklikler karşısında piyasadaki talebin tahmin edilebilmesi için anket yapılmasıdır. Yapılan anketlerde kişilerin cevaplarında net olmamaları, soruları anlayamamaları, cevapları öylesine vermeleri dezavantaj oluşturmaktadır. Anketler ile detaylı bilgi elde etmek zordur. Avantajı ise tahmin yönteminde para ve zaman sağlamasıdır.

3.4.1.3. Satış grupları yöntemi

Satış biriminde çalışanlar; tüketiciler ile sürekli iletişim halinde oldukları, onlarla bire bir ilişki kurdukları için gelecek ile ilgili tahminler, satış çalışanlarının görüşüne dayanır. Satış çalışanlarının, önyargıları olmaksızın, tüketici ile yüz yüze görüşme imkânı bulunduğundan satış tahminlerinin yapılmasında yarar sağlar. Bu yöntem, subjektif özellikler taşımasından dolayı güvenilir bir yöntem değildir.

3.4.1.4. Yönetici görüşleri yöntemi

Üst düzey yöneticilerin görüşlerinin talep tahmininde kullanılmasıdır. Bu yöntem geçmişe dayalı veri eksikliği sebebi ile tercih edilmektedir. Zamanın kısıtlı olduğu durumlarda kullanılır, zaman ve maliyet olarak avantajlıdır. Kişi görüşlerine dayanması sebebi ile dezavantaj oluşturmaktadır. Sorumluluk, yönetici konumundaki bireylerin kendilerine aittir.

3.4.1.5. Tarihi bilgi yöntemi

Geçmiş senelerdeki benzer ürün ya da ürün gruplarına ait olan verilerin, bilgilerin incelenmesi ile yapılan tahmin yöntemidir. Bu yöntemde, pazara yeni dahil olacak olan ürün ya da ürün gruplarında yapılacak değişikliklerde tüketicilerin taleplerine ve ihtiyaçlarına önem verilmelidir.

3.4.2. Kantitatif tahmin yöntemleri

İstatiksel metotlar ile geçmiş talep verilerinin analiz edilip gelecek dönemlerdeki talep miktarlarının bulunmasını sağlayan yöntemlerdir. Kantitatif tahmin yöntemleri ile tecrübeye gerek duymaksızın birçok farklı kişi tarafından kullanılarak tahmin yapılabilir. Verilere dayanılarak yapıldığından tahmin performansı yüksektir.

3.4.2.1. Zaman serileri analizi

Geçmiş zamandaki veriler analiz edilerek ve model kurulumu yapılarak gelecek verilerin tahmin edilmesidir. Bu veriler, belirli bir zaman sırasına ait geçmiş verilerdir. Bu; ay, yıl, gün, saat gibi bağımsız değişkenlerdir. Bağımlı değişkenler ise stok miktarı, ürün miktarı, verim yüzdesi gibi değerlerdir. Beklenmedik değişimler yaşandığında bu yöntemin uygulanması öngörülmez.

Zaman serisini etkileyen dört değişim şekli vardır. Bunlar:

Trend, verilerin benzer yönde değişimi, trend olarak adlandırılır. Regresyon modeli bu benzer değişimi iyi bir şekilde gösteren modeldir. Mevsimsel değişim, talebin mevsimsel, yani aylara göre değişkenlik göstermesidir. Yılın farklı aylarındaki talepteki değişimler buna örnek olarak gösterilebilir. Konjoktürel değişim, ekonomik şartlara göre oluşan değişimlerdir. Mevsimlere göre daha uzun süren, bir yıldan fazla değişimlerdir. Rastgele değişimler, belirli bir düzende olmayan değişimlerdir. Doğal afet, savaş, grev gibi belirsiz gerçekleşen durumlar karşısında ortaya çıkan dalgalanmanın meydana getirdiği talep değişkenliğidir (Sarı, 2016).

Zaman serileri analizinde kullanılan yöntemler; basit hareketli ortalama, ağırlıklı hareketli ortalama yöntemi, üssel düzeltme, holt lineer metodu, holt-winter yöntemi, box-jenkins yöntemi ve otoregresif modellerdir.

1. Basit hareketli ortalama yöntemi: Bir önceki n dönemdeki gerçekleşen talep değerlerinin ortalamasıdır. Daha doğru tahmin için belirlenecek n değeri, deneme yöntemi ile bulunabilir. Bu yöntem, hesaplanacak olan döneme ait değerlerin bir önceki gerçek değerlerden etkilendiğini göstermektedir. Formülasyon (3.1) aşağıda yer almaktadır.

$$F_t = \frac{Y_{t-1} + Y_{t-2} + Y_{t-3} + \dots + Y_{t-n}}{n} \quad (3.1)$$

F_t t dönemi için tahmini, Y_{t-1} önceki dönemde gerçekleşen değeri, n toplam dönem sayısını ifade etmektedir.

2. Ağırlıklı hareketli ortalama yöntemi: Talep dönemlerine ağırlıklar verilerek yakın olan dönemlerin ortalamada daha fazla etkisinin olması sağlanır. Gerçekleşen verilerin ağırlıkları farklı değerlerde düşünülerek yapılan bir hesaplama. Yakın dönemlerin ağırlığı daha fazla olup dönemden uzaklaştıkça ağırlık değeri azalır.

Ağırlıklar toplamı değer olarak "1" olmalıdır. Basit hareketli ortalamadan farkı ise dönemlere verilen farklı ağırlık değerleridir. Basit hareketli ortalamada dönemlerdeki ağırlık değerleri eşit kabul edilmiştir. Formülasyon (3.2) aşağıda yer almaktadır.

$$F_t = \frac{W_1 * Y_{t-1} + \dots + W_n * Y_{t-n}}{W_1 + W_2 + \dots + W_n} \quad (3.2)$$

W_n n dönemindeki gerçekleşen talebe verilen ağırlığı, W ağırlık değerlerini, Y gerçekleşen bağımsız değişken değerini ifade etmektedir.

3. Üssel düzeltme: Bir önceki dönemde olan hata değerine bakılır. Tahminde bulunulan dönem, bir önceki dönemde olan tahmin hatasının bir kısmı ile düzeltme yapılarak yeni bir tahminde bulunulur. Hata değeri pozitif ise tahminden büyük bir değer gerçekleşmiştir. α düzeltme sabiti kullanılarak tahmin hatası azaltılır. α değeri $0 \leq \alpha \leq 1$ arasındadır. Genellikle 0.05 ile 0.30 arasında değer olur. Uygun bir α değerinin seçilmesi gerekir. Formülasyon (3.3) aşağıda yer almaktadır.

$$F_{t+1} = \alpha * Y_t + (1 - \alpha) * F_t \quad (3.3)$$

F_{t+1} t periyodu için tahmini, F_t önceki dönem tahminini, Y_t önceki dönem talebini, α düzeltme sabitini ifade etmektedir.

4. Holt lineer (İkili üssel düzeltme) yöntemi: İki üssel düzeltme katsayısı kullanılarak tahmin yapılır. Bunlar α ve β 'dir. Serinin bir trende göre tahmin edilebilmesi için Holt, üssel düzeltme yöntemini geliştirerek Holt lineer yöntemini bulmuştur. Her iki düzeltme sabiti de 0 ile 1 arasında değer alabilir. Formülasyon (3.4), (3.5), (3.6) aşağıda yer almaktadır.

$$L_t = \alpha * Y_t + (1 - \alpha) * (L_{t-1} + b_{t-1}) \quad (3.4)$$

$$b_t = \beta * (L_t - L_{t-1}) + (1 - \beta) * b_{t-1} \quad (3.5)$$

$$F_{t+m} = L_t + b_t * m \quad (3.6)$$

L_t Serinin t zamandaki serisi, b_t serinin t zamandaki eğimi, m tahmin edilecek dönem sayısı.

5. Holt-winter yöntemi: Talep, doğrusal bir yapıya sahip değildir. Zaman serisine, trende ilaveten mevsimsellik eklendiği zaman uygulanır. Yöntemde 3 düzgünleştirme bulunur. α düzgünleştirme sabiti, β trend düzeltme sabiti, γ mevsimsellik için düzeltme sabitidir. Her üçü de 0 ile 1 arasında değer alır. Formülasyon (3.7), (3.8), (3.9), (3.10) aşağıda yer almaktadır.

$$L_t = \alpha * (Y_t - S_{t-s}) + (1-\alpha) * (L_{t-1} + b_{t-1}) \quad (3.7)$$

$$b_t = \beta * (L_t - L_{t-1}) + (1-\beta) * b_{t-1} \quad (3.8)$$

$$S_t = \gamma * (Y_t - L_t) + (1-\gamma) * S_{t-s} \quad (3.9)$$

$$F_{t+m} = L_t + b_t * m + S_{t-s+m} \quad (3.10)$$

F_{t+m} Trende ve mevsimselliğe göre $t + m$ dönemdeki tahmin değeri, L_t zaman serisindeki t anındaki serisi, b_t zaman serisindeki t anındaki eğimi, S_t zaman serisindeki mevsimsellik bileşimi, s mevsim uzunluğunu, m tahmin edilecek dönem sayısını ifade etmektedir.

6. Box-Jenkins yöntemi: 1970-1976 yıllarında Box-Jenkins tarafından geliştirilmiştir. Kesikli ve durağan tek değişkenli zaman serilerinin analizinde bu yöntem uygulanabilir. Box-Jenkins modelleri doğrusal, durağan stokastik modeller olarak da adlandırılmaktadır. Zaman serilerindeki herhangi bir dönemdeki değeri, serinin geçmiş zamanlardaki değerlerinin ve hata değerlerinin doğrusal bir birleşimidir. En uygun olan ve minimum sayıda parametre içeren doğrusal modeli bulmak Box-jenkins modelinin amacıdır. Öncelikle durağanlığı bozan unsurlar belirlenerek dönüşüm ile seri, durağan hale getirilir. Ve devamında uygun modelle tahmin gerçekleştirilir. Diğer yöntemlerden farkı, herhangi bir eğilime sahip olmamasıdır. Yöntemdeki adımlar aşağıdaki gibidir: (Sarı, 2016)

1. Dönüştürme: Verilere dönüştürme işlemi uygulanır. p ve q'nun derecelerinin bulunması adımıdır. Bu dereceler, hareketli ortalama ve otoregresif özellikler ile bulunur.
2. Model tanımı: Deneme olarak birden çok model tanımlanır. Bu modeller içerisinde uygun olanı öngörü olarak seçilir.
3. Tahmin: Modellerdeki tahminler yapılır ve en iyi olan model seçilir. En iyi olan modelin seçiminde kişinin bilgi ve tecrübe seviyesi önemlidir. Devamında parametre tahmini yapılır.
4. Kontrol: Model yetersiz ise ikinci aşamaya geri dönülerek modeller tekrar değerlendirmeye alınır. Başka bir model ile adımlar tekrar edilir ve en uygun olan model belirleninceye kadar bu aşamalar tekrar edilir.
5. Tahmin: Belirlenen en uygun model ile istenilen dönemler için tahmin yapılır. Seriyeler eklendikçe tahmin değerleri de güncellenir.

3.4.2.2. Nedensel yöntemler

Talep ile talebi etkileyen faktörler arasındaki ilişkiyi de açıklayarak neden-sonuç yapılmasını amaçlayan yöntemdir.

Talebin gelecekteki değerinin bilinmesi dışında, onu etkileyen etkenler ile ilişkisinin matematiksel modelinin bulunması sağlanır. Bu yöntemler regresyon analizi ve korelasyon analizidir.

1. Regresyon analizi: Bağımlı değişkenlerin, bağımsız değişkenler ile olan ilişkisinin ne kadar yakın olduğunu ölçen bir analiz metodudur. Buna tek bir bağımsız değişken kullanılıyorsa tek değişkenli, birden fazla değişken kullanılıyorsa çok değişkenli (çoklu) regresyon analizi denir. Aradaki ilişkiyi belirlemek için kurulan matematiksel modellere de regresyon modelleri denir. Bunun için iki teknik kullanılır. Bunlar en

küçük kareler tekniği ve en büyük olabilirlik tekniğidir. Hatanın normal bir dağılım varsayımı var ise en büyük olabilirlik, bir varsayım yok ise en küçük kareler tekniği uygulanır.

Tek değişkenli regresyon analizi: Tek bir bağımsız değişken kullanarak bir bağımlı değişken ile bir bağımsız değişken arasındaki ilişkiyi analiz eden bir tekniktir. Aradaki ilişkide ve değişkenlerde doğrusallık vardır. Formülasyonu (3.11) aşağıdaki gibidir.

$$Y_i = \beta_0 + \beta_i * X_i + \varepsilon_i \quad i=0,1,2\dots n \quad (3.11)$$

X_i Seçilen bağımsız değişkenin değerini, Y_i tahmin edilen Y değerini, β_0 doğrunun Y eksenini kestiği noktayı, β_i doğrunun eğimini, ε_i hata bileşenini (i. Gözlem için hata bileşeni) ifade etmektedir.

Çok değişkenli regresyon analizi: Bir bağımlı değişken ile birden fazla bağımsız değişken arasındaki ilişkiyi analiz eden tekniktir.

2. Korelasyon analizi: Değişkenler arasındaki ilişkinin derecesini gösterir. Değişkenler, doğrusal ilişkili değişiyorsa korelasyon vardır. İlişki ne kadar güçlüyse tahmin de o kadar iyidir. Korelasyon katsayısı, +1 ile -1 arasında olan ilişkinin derecesini ölçen bir değerdir. İlişki yok ise R, 0'dır. -1'e yakın ise negatif doğrusal ilişki vardır. +1'e yakın ise pozitif doğrusal ilişki vardır. Aşağıdaki denklemde (3.12) ifade edilmektedir.

$$R = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{\sqrt{(n \sum X^2 - (\sum X)^2) (n \sum Y^2 - (\sum Y)^2)}} \quad (3.12)$$

3.4.2.3. Yapay zeka çözümlü yöntemler

Yapay zeka terimi, 1956'da John McCarthy tarafından Dartmouth Konferansı'nda kullanılmıştır (Dick, 2019). Yapay zeka; insan zekasına özgü olan geçmiş

deneyimleri öğrenme, akıl yürütme, anlam keşfetme, karar verme gibi davranışları sergileyen bir yapay işletim sistemidir. Yapay zeka, insanın yapabileceği bazı davranışların daha hızlı şekilde yapılmasını sağlar. Bu sebeple günlük hayatımızda bulunmaktadır. Birçok alanda karar verme süreçlerine yardım ederken daha hızlı ve kaliteli bir hizmet sunarak gün geçtikçe daha fazla ihtiyaç duyulmaktadır. Talep tahminleri için sıklıkla tercih edilenler; yapay zeka çözümleri, bulanık mantık ve yapay sinir ağlarıdır. Yapılan bu çalışma için yapay sinir ağları yöntemi tercih edilmiştir.

1. Bulanık Mantık: Bulanık mantık kavramı 1965 yılında Zadeh tarafından “Bulanık Mantık ve Bulanık Kümeler Kuramı” adlı makalede ortaya atılmıştır. İlk kez 1973 yılında bir buhar makinesinde uygulanmıştır. İnsan davranışlarını taklit ederek belirsiz çözümler ve sayısal modellemeler ortaya çıkarır. Bulanık mantıkta doğru ya da yanlış yoktur. Doğruya yakın, yanlışla yakın gibi belirsiz seçenekler dikkate alınır.

Bulanık mantık klasik bir küme yerine bulanık küme teorisine dayanır. Klasik mantık 0 ya da 1 değerini alır. Ama bulanık mantık 0 ile 1 arasındaki değerleri alır. Klasik yöntemlerden farklı 3 aşama kullanılır: bulanık kümelerin meydana getirilmesi, karar verme, kuralların yazılması (Klir & Yunan, 1995).

Avantajları ise belirsiz karmaşık sistemlere basit çözümler getirir, insan zekasını taklit eder, matematiksel modele ihtiyaç yoktur ve uygulaması kolaydır.

Dezavantajları ise deneyime ihtiyaç duyar, bu nedenle deneme yanılma yöntemlerinin uygulanması uzun zaman alabilir.

2. Yapay sinir ağları: İnsan beyninin öğrenme yolu ile yeni bilgiler oluşturabilmesini sağlayan bilgisayar sistemleridir. Öğrenme sürecinin matematiksel modellenmesi olarak ortaya çıkmıştır. Biyolojik sinir ağlarını taklit eden yapılardır. 4. bölümde detaylı olarak anlatılmıştır.

BÖLÜM 4. YAPAY SİNİR AĞLARI

4.1. Yapay Sinir Ağlarının Tanımı

YSA, insan beynini taklit ederek tasarlanmış olan bilgisayar sistemleridir. Bu yöntem ile öğrenme, ezberleme ve bilgiler arasında ilişkiler kurarak sonuç elde edilir. Kendi kendine öğrenme özelliğine sahiptir. Biyolojik sinir ağlarını taklit eden insan beynindeki sinir hücrelerinden esinlenerek oluşturulmuştur. Hesaplaması zor, imkânsız olan olaylar için büyük kolaylık sağlayan sistemdir.

4.2. Yapay Sinir Ağlarının Tarihçesi

1943 yılında nörolog Warren McCulloch ve bilim adamı Walter Pitts tarafından ilk YSA çalışması, basit bir şekilde matematiksel yapısını modelleyerek yapılmıştır. 1949 yılında Hebb tarafından, Hebbian öğrenme kuralı geliştirilerek bağlantı sayısı değiştiğinde öğrenmenin devam edeceği öngörülmüştür. 1950 yılından sonra IBM laboratuvarlarında yapılan yapay sinir ağı simülasyon çalışmalarından ilki olumsuz sonuçlanmıştır, sonraki çalışmalar başarılı olmuştur. 1957 yılında Frank Rosenblatt tarafından algılayıcı modeli ortaya koyulmuştur. Öğrenmenin, fiziksel parametreler ile tahmin edilebilir olduğunu belirtmiştir. Tek katmanlı eğitilebilen, tek bir çıkışa sahip olan yapay sinir ağı “PerCeptron” un keşfinden sonra çalışmalar hız kazanmıştır. Rosenblatt, sineğin gözüne yaptığı çalışma ile “kavrama düğümü” olarak adlandırılan en eski yapay sinir ağının doğmasına sebep olmuştur. John Von Neuman, telgraf röleleri ve vakum tüpleri ile sinir işlevinin benzetilmesini önermiştir. 1959 yılında Bernard Widrow ve Marcian Hoff tarafından mühendislikteki uygulamalara yönelik olan ADALINE (Adaptive Linear Neuron) ve MADALINE adlı ilk yapay sinir ağı modellerini geliştirdiler. Madaline ağ modeli,

telefon hatlarındaki ses yankılarını yok etmek için kullanılmış olup hala kullanılmakta olan bir yapay sinir ağıdır. Yapay sinir ağı ile ilgili çalışmalar devam ederken yapay zeka kavramı ortaya atılarak dikkatler yapay zekaya çevrilmiştir. 1969 yılında Pappert ve Minsky tarafından “Algılayıcılar” isimli kitap yazıldı. Bu kitapta yapay sinir ağlarının lineer problem çözüm üretmediğini ve bilimsel bir değere sahip olmadığını savunarak kanıtlamak için ise XOR problemlerinin çözümünü örnek olarak gösterdiler. 1970 yılında Fukushima, “Neocognitron” modeli olan doğru görüntü işlemeyi, literatüre kazandırmıştır. 1972 yılında Andersan ve Kohonen “çağrışımli bellek” konusunda benzer çalışmalar yayınladılar. 1982 yılında Hopfield, gezgin satıcı problemlerini çözerek bilgisayar yazılımları ile zor problemlere çözüm olacağını göstermiştir. 1986 yılında Rumelhart, çok katmanlı algılayıcıların ortaya çıkmasında önemli adım atarak 2 ciltlik eserini yayınlamıştır. 1986 yılında geri yayımlı öğrenme algoritması Rumelhart ve McClelland tarafından ortaya atılmıştır. 1987 yılında 2000 kişilik ilk yapay sinir ağı konferansı gerçekleşmiştir. 1988 yılında Broomhead ve Lowe çok katmanlı algılayıcılara alternatif olarak “radyal tabanlı fonksiyonlar” modelini geliştirmişlerdir. 1991 yılında Specht, “Genel Regresyon Ağları” ve “Probalistik Ağları” ile bunu daha da geliştirmiştir (Keskenler & Keskenler, 2017).

4.3. Yapay Sinir Ağlarının Genel Özellikleri

YSA'nın en önemli özelliklerinden biri, doğrusal olmayan yapılarda iyi sonuçlar vermektedir. Doğrusal olmayan yapılar ile çalışmak zordur. YSA ile doğrusal olmayan yapılarda verdiği sonuçlarla kolaylıklar sağlamaktadır. Geleneksel yöntemlerdeki gibi yavaş bir birimin olması, sistemin yavaşlamasını sağlamaz. YSA'da yavaş bir birim, o sistemin hızını yavaşlatmaz. Geleneksel yöntemlerde ise sistemin yavaşlamasını sağlar. Kendi kendilerine veriyi öğrenebilir ve organize edebilirler. Kendi kendine öğrenme yeteneğine sahiptirler. Veriyi, örnekler ile öğrenerek olay ile ilgili genelleme yapabilecek duruma gelirler. Genelleme ile görülmemiş örneklere bilgiler üretir. Ağda bazı yerlerdeki bozulmalar, ağın çalışmasına engel olmaz. Hatalara karşı toleransa sahip oldukları için ağ çalışmaya devam eder, sadece performansında düşüklük olabilir. Eksik verilerle çalışabilirler.

Eksik bilginin olması durumunda çalışmayı engellemeyerek hatayı tolere etmeye çalışacaktır. Sınırsız sayıda değişken ve parametre kullanılarak çalışabilmektedirler. Bu sınırsız sayıdaki değişken ve parametreleri gerektiği anda kullanılacak şekilde eğitilirler. YSA'da değişken ve parametrelerinde değişiklik olduğunda uygun çözümler için tekrar eğitilebilirler (Öztemel, 2016).

4.4. Yapay Sinir Ağlarının Dezavantajları


Ağ yapısı belirlenirken belirli bir kuralları yoktur. Deneme yanılma yöntemiyle, tecrübe ve sezgiye göre uygun ağ yapısı bulunur. Belirli sayıda veri seti olması gerekiyor. Hem eğitim için hem de test için yeterli veri olmalıdır. Gizli katmandaki nöron sayısı, eğitimin hızını ve doğruluğunu etkilemektedir. Nöron sayısı az olduğunda sonuç bulunamamakta, çok olduğunda ise de hesaplamayı artırmaktadır. Sadece sayısal veriler ile çalışır. Örnekleminin ağa sunulması, sayısal bir değere dönüştürülerek yapılır. Ağın eğitiminin ne zaman bitirileceği bilinmemektedir. Bunun için belirli bir yöntem yoktur. Ağın davranışları bilinmediği için bu da güveni azaltmaktadır. YSA'ları donanıma bağımlı çalıştırmak bir problemdir. YSA'lar herhangi bir problemi çözemezler, sadece daha önce öğrendiklerine göre sonuç üretebilirler (Öztemel, 2016).

4.5. Yapay Sinir Ağlarının Yapısı

4.5.1. Biyolojik sinir hücreleri

Yapay sinir hücreleri, biyolojik sinir hücrelerinden esinlenerek oluşturulmuş olan modellerdir. Yapay sinir ağlarını daha iyi anlamak için önce biyolojik sinir hücrelerini inceleyelim. Bir biyolojik sinir hücresi üç katmandan oluşur. Bu katmanlar; alıcı sinirler, tepki sinirleri ve merkezi sinir sistemidir. Öğrenme, düşünme, hatırlama gibi her türlü davranışın temelini nöron hücreleri oluşturmaktadır. Sinir sisteminin temeli elemanı olan nöronlar; dentrit, çekirdek, akson ve sinapstan oluşmaktadır. Dentrit, girdi sinyallerini alır. Çekirdek, girdi sinyallerini işler. Akson, girdi sinyallerini çıktı

sinyallerine çevirir. Sinapslar, nöronlar arasındaki elektrokimyasal bağlantıyı sağlar. Şekil 4.1.'de biyolojik bir sinir hücresi gösterilmiştir.




Şekil 4.1. Biyolojik bir sinir hücresi (Kriesel, 2007)

YSA'larda, biyolojik sinir sisteminin davranışını taklit ederek oluşturulmuş olan matematiksel modelli algoritmalarıdır.

4.5.2. Yapay sinir hücreleri

Yapay sinir hücreleri, biyolojik sinir hücrelerinin yapısına benzetilen, insan beyninin çalışma şeklini örnek alan yapılardır. Doğrusal olan ya da olmayan 5 ana elemandan oluşurlar. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı birimleridir. Biyolojik sinir sistemindeki nöronlar, işlemci elemanına; dentrit, toplam fonksiyonuna; hücre gövdeleri, aktivasyon fonksiyonuna; sinapslar, ağırlıklara; aksonlar ise yapay nöron çıkışına benzetilmektedir. Yapay sinir hücresi Şekil 4.2.'de gösterilmiştir.



Şekil 4.2. Yapay sinir hücresi (Kurt, et al., 2017)

1. Girdiler: Yapay sinir hücresine gelen verilerdir. Veriler başka hücrelerden, kendisinden ya da bağımsız şekilde gelebilir (Kargı, 2015).
2. Ağırlıklar: Hücreye gelen bilgilerin önemini göstermektedir. Ağırlıkların az ya da çok olması önem derecesini göstermemektedir (Elmas, 2021).
3. Toplam fonksiyonu: Hücreye gelen, net girdiyi hesaplayan fonksiyon, toplam fonksiyonudur. Çoğunlukla her girdi, kendi ağırlığı ile çarpılarak toplamları alınmaktadır. Denklem (4.1) aşağıdaki gibidir.

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

G girdileri, A ağırlıkları, n ise toplam girdi sayısını göstermektedir. Çoğunlukla kullanılan bu formüldür, her zaman kullanılmayabilir.

4. Aktivasyon fonksiyonu: Hücrelere gelen girdiyi işleyerek çıktıyı belirleyen fonksiyondur. Aktivasyon fonksiyonu için çeşitli formüller kullanılmaktadır. Genellikle sigmoid fonksiyonu kullanılır. Aşağıdaki (4.2) gibidir. (Yanık, 2019)

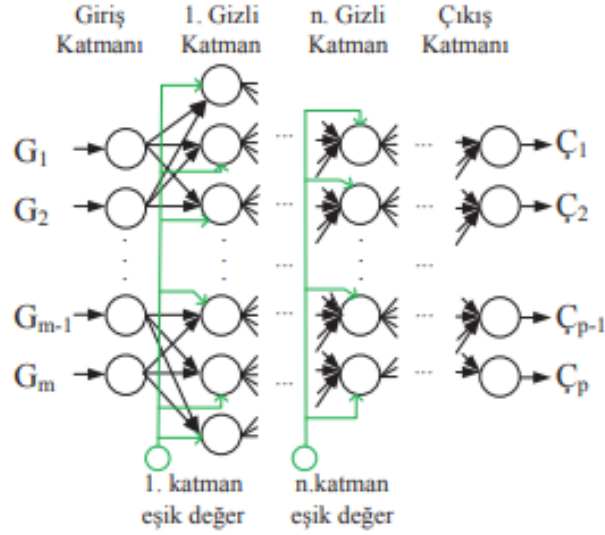
$$F(NET) = \frac{1}{1 - e^{-NET}} \quad (4.2)$$

NET prosese gelen net girdi değerini gösterir.

5. Hücre çıktısı: Aktivasyon fonksiyonunun belirlemiş olduğu değerdir. Bu değer, kendi hücresine veya başka bir sinir hücresine girdi olarak gönderilebilir. Birden çok girdi olabilir, fakat tek bir çıktı değeri vardır. (Yanık, 2019)

Yapay sinir ağları 3 katmandan oluşmaktadır. Bunlar; girdi katmanı, ara katman ve çıktı katmanıdır. Girdi katmanında en az bir girdi mevcuttur. Bu girdi değeri, alınarak ara katmana iletilir. Ara katmana gelen veriler, işlenerek çıktı katmanına iletilir. Bazı ağlarda ara katman, birden fazla ara katmandan oluşabilir. Çıktı katmanı,

ara katmana gelen verileri işleyerek girdi katmanı için uygun bir çıktı verisi üretir (Şekil 4.3.).



Şekil 4.3. Yapay sinir ağı (Akpınar, 2017)

4.6. Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağları, yapılarına (ağ modellerine) göre ve öğrenme yöntemlerine göre farklı sınıflara ayrılmaktadır. Yapay sinir ağlarının sınıflandırılması aşağıda gösterilmiştir.


4.6.1. Yapay sinir ağlarının ağ modellerine göre sınıflandırılması

Yapay sinir ağları, yapılarına göre iki farklı şekilde sınıflandırılmaktadır. Bunlar; ileri beslemeli ağlar, geri beslemeli ağlardır. Bu ağlar, yapay sinir ağlarında nöronların birbirlerine bağlanış şekillerine göre değerlendirilmektedir. Bağlantının şekli ağın yapısını belirler. Bağlantının nasıl olması gerektiği öğrenme yöntemine göre belirlenebilir (Serttaş, 2011).

4.6.1.1. İleri beslemeli ağlar

Bu ağ yapısında çıktılar hızlı bir şekilde sonuçlandırılır. İleri beslemeli ağlarda, döngü olmadan giriş kısmından çıkış kısmına nöronlar, belirli düzende katmanlar halinde ilerler. Bir katmandaki çıktı, diğer katmana girdi olarak iletilir ve aynı katmanda bağlantı kurulamaz.

Bu ağlarda veri akışı tek yönlü olarak geriye dönülmeksizin iletilmektedir. Girdiden gizliye, gizliden de çıktıya iletilen bilgiler işlenerek ağ çıktısı olarak belirlenir. Ağın gizli katmanındaki nöronlarda doğrusal olmayan davranışından dolayı ağ, doğrusal değildir. İleri beslemeli ağların yapısı aşağıdaki şekilde gösterilmektedir (Şekil 4.4.).




Şekil 4.4. İleri beslemeli ağ yapısı (Öztürk & Şahin, 2018)

4.6.1.2. Geri beslemeli ağlar

Geri beslemeli ağlarda, geri besleme bir gecikme elemanı ile yapılmaktadır. Doğrusal olmayan davranışa sahiptirler. Geri besleme, hataları geriye doğru azaltmaya çalışarak çıkıştan geriye doğru ilerlediğinden bu şekilde adlandırılır.

3 katmana sahiptirler. Bunlar; giriş katmanı, gizli katmanı ve çıkış katmanlarıdır. Duruma göre gizli katmanın sayısı artırılabilir. Geri beslemeli ağlarda, bir döngü olduğundan dolayı ağların eğitime süresi uzun sürmektedir. Geri beslemeli ağların yapısı aşağıdaki şekilde gösterilmektedir (Şekil 4.5.).



Şekil 4.5. Geri beslemeli ağ yapısı (Kurnaz, 2014)

4.6.2. Yapay sinir ağlarının öğrenme yapısına göre sınıflandırılması

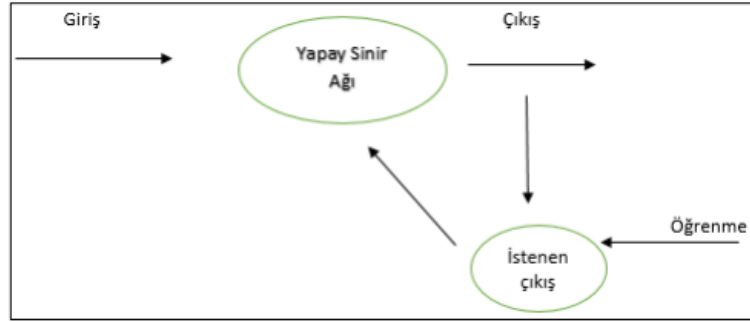
Yapay sinir ağlarında öğrenme örneklerle yapılır. Öğrenmenin tamamlanması, ağırlıkların doğru değere ulaşması ile son bulur. Ağ, örnekler ile ağırlıklarda ayarlamalar yapar; ayarlama sonucunda doğru ağırlık değeri bulunur. Bu doğru ağırlıkların belirlenmesi öğrenme stratejisi ve kuralları ile gerçekleşmektedir. Öğrenmede, en az bilgi ile en iyi şekilde öğrenmenin olacağı eğitim verileri seçilmelidir.

Doğumdan sonra insan beyni, çevresinde gördüğü olayları yorumlar ve öğrenir. Tecrübe kazanarak olaylar karşısında nasıl tepki vermesi gerektiğini bilir. Daha önce tecrübe edilmemiş olaylar karşısında kalabilirler. Yapay sinir ağları da aynı insan beyni gibi tecrübe ettiği davranışları karşılaştırarak bir hata bulur. Hata azaltılarak doğru çıkışa yaklaştırılmaya çalışılır. Bulunması gereken sonuç ile üretilen sonuç arasındaki hatayı en aza indirmek için işlemler tekrarlanır. Bu tekrarlama işlemlerinin her birine devir (epoch) denir.

Yapay sinir ağlarında öğrenme; danışmanlı, danışmansız ve destekleyici stratejiler olarak 3 yöntem kullanılır.

4.6.2.1. Danışmanlı öğrenme


Danışmanlı öğrenmede, ağa hem giriş bilgileri hem de çıkış bilgileri sunulmaktadır. Ağı, girdi ve çıktı değerleri oluşturur. Bu çıktı değerleri ile verilen çıktı değerleri karşılaştırılarak bir hata seviyesi oluşmuş olur. Bu hata seviyesini en aza indirmek için ağırlıklarda yeniden düzenleme yapılır ve en yakın değerler elde edilmeye çalışılır. Ağı eğitiminde kullanılacak verilerin önemi, süreç ve performans açısından büyüktür. Bu sebeple eğitim verileri, bütün ihtiyaç duyulan bilgileri içermesi gerekmektedir. Bunun için veri setinin çok olması gerekir (Şekil 4.6.) (Olgun, 2009).



Şekil 4.6. Danışmanlı öğrenme algoritması (Korkut, 2019)

4.6.2.2. Danışmansız öğrenme

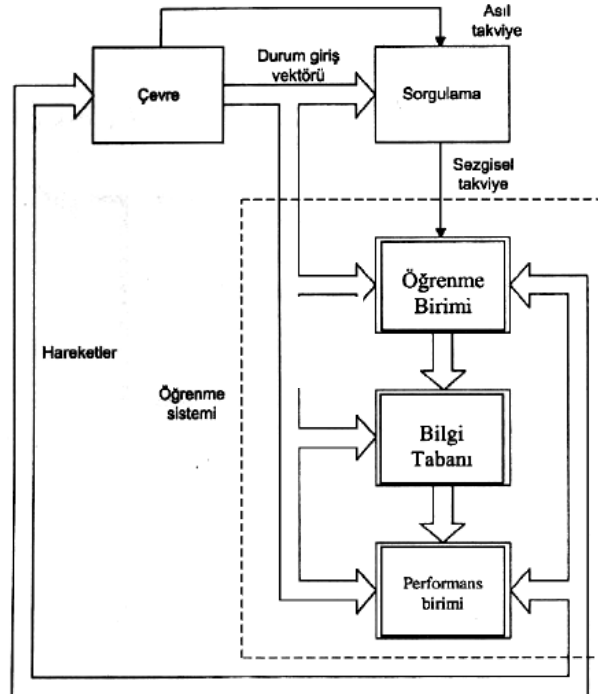
Danışmansız öğrenme şeklinde, istenen çıktı değerleri ağa verilmemektedir. Yalnız girdi değerleri verilerek bir çıktı oluşturulur. Günümüzde sadece sınıflandırma problemlerinde kullanılır. Girdi değerleri, çıktı görevi de görür. Ağ tarafından girdi değerleri analiz yapılarak, ağırlıklar oluşturularak müdahale edilmeksizin bir çıktı değeri oluşturulur. Danışmansız öğrenme şekli aşağıdaki şekilde gibidir (Şekil 4.7.).



Şekil 4.7. Danışmansız öğrenme algoritması (Kargı & Öztürk, 2013)

4.6.2.3. Destekleyici öğrenme

Danışmanlı öğrenmeye benzer bir öğrenme çeşidi denilebilir. Danışmanlı öğrenmede ağa çıktılar da verilmektedir. Destekleyici öğrenmede ise ağa, çıktılar verilmeden ağın çıktı üretmesi beklenir. Çıktının yanlış ya da doğru olduğunu belirten bir uyarı üretilir. Ağ, bu uyarıcı ile ağırlık değerlerini gözden geçirerek gerekli değişimleri sağlayıp öğrenme sürecini devam ettirir. Destekleyici öğrenme aşağıdaki şekilde gibidir (Şekil 4.8.) (Öztemel, 2016).



Şekil 4.8. Destekleyici öğrenme algoritması (Aydın , 2012)

4.7. Yapay Sinir Ağlarında Öğrenme Kuralları

4.7.1. Hebb kuralı

Danimarkalı Donald Hebb tarafından geliştirilen, en eski olan ve tüm öğrenme kurallarının temelini oluşturan, en yaygın kullanılan bir öğrenme kuralıdır. Bu öğrenme kuralına göre bir ağda, iki nöron arasındaki ilişki aynı anda ateşleniyorsa ve iki nöron aynı işarete sahipse güçlendirildiğinde ağırlıkları artar ve öğrenmenin gerçekleştirilmiş olduğu belirlenir. Aksi halde, aradaki bağın gücü azaltılmalıdır. Nöronların aynı işarete sahip olduklarındaki güçlendirilmesiyle, ayrı işarete sahip olduklarındaki güçlendirilme kuvveti aynı etkiye sahip olmayabilir (Yücesoy, 2011).

4.7.2. Hopfield kuralı

Hebb kuralına benzer bir kuraldır. Hebb kuralından tek bir farkı bulunmaktadır. Hebb kuralındaki nöronlar arasındaki bağlantının güçlendirilmesi ya da zayıflatılmasına ilaveten, bu bağlantının büyüklüğünün belirlenmesi Hopfield kuralını oluşturmaktadır. Bu kurala göre girdi ve çıktı değeri aktif ya da pasif olması durumunda bağlantı ağırlığı, öğrenme oranı kadar artırılır. Aksi halde öğrenme oranı kadar azaltılır. Öğrenme oranı genellikle 0-1 arasında sabit bir değer almaktadır (Olgun, 2009).

4.7.3. Delta kuralı


Hebb kuralının daha da geliştirilmiş hali olan ve yaygın olarak kullanılan kurallardan biridir. Delta kuralı, beklenen çıktı değeri ile gerçekleşen çıktı değeri arasındaki farkı minimize etmek için, giriş bağlantı ağırlıklarının sürekli değiştirilmesi gerektiği prensibine dayanır. Hata, bir önceki katmana geri iletilir ve ilk katmana ulaşınca kadar devam ettirilir. Ağırlıklarda sürekli güncellemeler yapılmaktadır. Bu tip ağ, ileri beslemeli geri yayımlı yapay sinir ağı olarak adlandırılır.

4.7.4. Kohonen kuralı

Teuvo Kohonen tarafından geliştirilen bu kural, sinir hücrelerinin birbirleriyle rekabet ederek yarışmaları ilkesine dayanmaktadır. En büyük çıktıyı veren süreç elemanının, nöronlar arasındaki bağlantı ağırlıkları güncellenir. Kazanan süreç elemanı, diğer elemanların da ağırlıklarının değiştirilmesine izin verir. Bu kurala göre ağ, danışmansız olarak kendi kendini eğitilebilir. Ağın hangi özellikleri kullanacağına da kendisi karar verir (Gürsoy, 2012).

4.8. Geri Yayılım Algoritması ve Çok Katmanlı Algılayıcılar

YSA'daki, yapay sinir hücrelerinin oluşturduğu kümeye katman denir. Girdi katmanı, girdi sinir hücrelerinden; çıktı katmanı ise çıktı sinir hücrelerinden oluşur. YSA'nın birden fazla katmandan oluşmasına çok katmanlı yapay sinir ağları denilir. Talep tahmin yöntemlerinde en uygun olan, çok katmanlı modellerdir. ÇKA'lar danışmanlı öğrenmeye uygulanan ileri beslemeli ağlardır. ÇKA ağının öğrenme kuralı, delta öğrenme kuralıdır. ÇKA'larda 3 katman bulunmaktadır. Bunlar; girdi katmanı, çıkış katmanı ve gizli nöronlardan oluşan bir veya daha fazla olan gizli katmandır. Ağa hem girdiler hem de girdilere karşılık oluşturulması gereken çıktılar, eğitim sırasında verilir. ÇKA'larda girdi ve çıktı ilişkileri lineer değildir. ÇKA'lar yüksek derecede bilgi işleme yeteneği gösterir. Ağ yapısı eğitilirken iki aşamadan biriyle eğitilir. Bunlar ileri beslemeli ve geri beslemelidir (Şekil 4.9.).



Şekil 4.9. ÇKA'nın yapısı (Doğan, 2019)

4.8.1. Çok katmanlı algılayıcılarda ileri besleme

ÇKA'larda ileri besleme aşamasında ağırlık almış olduğu girdiler, çıktı katmanına kadar ileri doğru gönderilir. Geri yayılım kısmında ise istenen çıktı ile elde edilen çıktı arasında fark, geriye doğru giriş katmanına kadar gönderilir. Bu hata, ağırlıklarda güncelleme yapılarak en aza indirgenmeye çalışılır. İleri beslemede ağırlık çıkışı hesaplanır. Girdi katmanındaki girdiler, herhangi bir işlem yapılmaksızın gizli katmana gönderilir. Gizli katmandaki süreç elemanları, girdi katmanından gelen verileri ağırlıklandırarak alır. Gizli katmandaki süreç elemanlarına gelen girdi, aşağıdaki denklemdeki (4.1) gibi hesaplanır (Yazıcıoğlu, 2010).

$$NET_j^a = \sum_{k=1}^n W_{jk} y_k^i \quad (4.1)$$

W_{jk} k. Girdi katmanı elemanını, j. gizli katmanı elemanına bağlayan ağırlık değerini gösterir. y_k^i Girdi katmanındaki k. süreç elemanının çıktısını belirtir. Geriye doğru hesaplamada aktivasyon fonksiyonu olarak da türevi alınabildiğinden dolayı sigmoid fonksiyonu kullanılır. Denklemi (4.2) aşağıdaki gibidir.

$$y_j^a = \frac{1}{1 + e^{-(NET_j^a + \beta_j^a)}} \quad (4.2)$$

β_j Gizli katmandaki j. elemana bağlanan eşik değer elemanının ağırlığını ifade eder. Bu değer, eğitim sırasında ağ tarafından belirlenir. Gizli ve çıktı katmanlarındaki elemanların çıktıları da bu şekilde hesaplanır. Bütün bu işlemlerin sonunda ağırlık ileri doğru hesaplaması bitirilmiş olur.

4.8.2. Çok katmanlı algılayıcılarda geri besleme

ÇKA'larda geriye doğru hesaplamada, ağa verilmiş olan çıktı ile elde edilen çıktı karşılaştırılır. Oluşan hatayı minimize etmek için, ağırlıkları revize etmek ederek geri

doğru hesaplama yapılır. Çıktı katmanındaki m. süreç elemanına ait hata aşağıdaki denklemdeki (4.3) gibidir.

$$E = d_m - y_m \quad (4.3)$$

E hata değeri, d_m tahmin değeri, y_m ise gerçek değeri belirtir. Çıktı katmanındaki tüm hatalar ise aşağıdaki denklemdeki (4.4) gibi hesaplanır.

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

Hatayı minimize etmek için geriye doğru hesaplamada ağırlıkların iki şekilde değiştirilebilir.

1. Gizli katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi: Gizli katman ile çıktı katmanı arasındaki ağırlığın, j. süreç biriminin çıktı katmanındaki m. süreç birimine bağlayan bağlantının ağırlık değişimi ΔW_{jm}^α 'dır. Bunun t zamandaki değişim miktarı ise aşağıdaki denklemdeki (4.5) gibidir.

$$\Delta W_{jm}^\alpha(t) = \lambda \delta_m y_\alpha^i + \alpha \Delta W_{jm}^\alpha(t-1) \quad (4.5)$$

λ Öğrenme oranı, ağırlıkların sonraki güncellemede ne kadar değişeceğini gösterir. A momentum katsayısı ise ağırlık performansı üzerinde etkiye sahiptir. δ_m m. süreç elemanının hatasını belirtir ve aşağıdaki denklemdeki (4.6) gibi hesaplanır.

$$\delta_m = f'(NET) E_m \quad (4.6)$$

$f'(NET)$ aktivasyon fonksiyonunun türevidir. Sigmoid fonksiyonu kullanılır ise aşağıdaki denklemdeki (4.7) gibi hesaplanır.

$$\delta_m = y_m(1 - y_m)E_m \quad (4.7)$$

Değişim miktarı belirlendikten sonra ağırlıkların t. tekrardaki değerleri ise aşağıdaki denklemdeki (4.8) gibi hesaplanır.

$$W_{jm}^\alpha(t) = \Delta W_{jm}^\alpha(t-1) + \alpha \Delta W_{jm}^\alpha(t) \quad (4.8)$$

Eşik değer elemanı ağırlıklarında güncelleme yapılır. Öncelikli olarak değişim miktarı hesaplanır. Çıktı katmanında bulunan süreç elemanının eşik değer ağırlığı β^o ise bu elemanın çıktısı sabit ve 1 olduğundan dolayı değişim miktarı aşağıdaki denklemdeki (4.9) gibi hesaplanır.

$$\Delta \beta_m^o(t) = \lambda \delta_m + \alpha \Delta \beta_m^o(t-1) \quad (4.9)$$

Eşik değeri t. tekrardaki ağırlığın değeri ise aşağıdaki denklemdeki (4.10) gibi hesaplama yapılır.

$$\beta_m^o(t) = \beta_m^o(t-1) + \Delta \beta_m^o(t) \quad (4.10)$$

2. Gizli katmanlar arası ya da gizli katman ile girdi katmanı arasındaki ağırlıkların değiştirilmesi: Ağırlıklardaki değişim miktarı ΔW^i , aşağıdaki denklemdeki (4.11) gibidir.

$$\Delta W_{kj}^i(t) = \lambda \delta_j^a y_k^i + \alpha \Delta W_{kj}^i(t-1) \quad (4.11)$$

δ_j^a Hata terimidir ve aşağıdaki denklemdeki (4.12) gibi hesaplanır.

$$\delta_j^a = f'(NET) \sum_m \delta_m W_{jm}^a \quad (4.12)$$

Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılırsa hata değeri aşağıdaki denklemdeki (4.13) gibi hesaplanır.

$$\delta_j^a = y_j^a(1 - y_j^a) \sum_m \delta_m W_{jm}^a \quad (4.13)$$

Değişim miktarından sonra ağırlıkların t. tekrarlamaadaki değerleri aşağıdaki denklemdeki (4.14) gibi hesaplanır.

$$W_{kj}^a(t) = W_{kj}^a(t-1) + \Delta W_{kj}^a(t) \quad (4.14)$$

Eşik değerler güncellenir. Eşik değerlerindeki değişim miktarı $\Delta\beta^o$ aşağıdaki denklemdeki (4.15) gibi hesaplanır.

$$\Delta\beta_j^a(t) = \lambda\delta_j^a + \alpha\Delta\beta_j^a(t-1) \quad (4.15)$$

Ağırlıkların yeni değerleri t. tekrarlamaada aşağıdaki denklemdeki (4.16) gibi hesaplanır.

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta\beta_j^a(t) \quad (4.16)$$

İterasyon, önce ileri sonra da geri hesaplamaları yapılarak bitirilir. Öğrenme işlevi bitinceye kadar iterasyonlara devam edilir.

4.8.3. Çok katmanlı algılayıcı ağı çalıştırma prosedürü

ÇKA'da ağların çalıştırma şekli, ağın öğrenimi için ilk olarak, gerçekleşmiş olan durumların toplanması ile başlanır. Ağın toplam katman sayısı ve katmanlardaki işlemleri belirlenir. Ağın öğrenme parametreleri ve fonksiyonları belirlenir. Giriş ve gizli katmanları için ağırlıkların ataması yapılır. Öğrenme verilerinden örnekler alınarak ağa gösterilir. Ağın hata değeri belirlenir. Ağın ürettiği çıktı ile gerçek çıktı arasındaki fark olan hata bulunur. Geriye doğru hesaplama yapılarak hata değerini

minimize etmek için ağırlık değerlerinde deęişiklik yapılır. Hata deęeri kabul edilebilir seviyeye gelinceye kadar tüm bu adımlar tekrarlanır (Sarı, 2016).

BÖLÜM 5. TALEP TAHMİNİ UYGULAMASI


Mobilya sektörü, Türkiye'nin en hızlı gelişen sektörlerinden biridir. Sektör her yıl ürün çeşitliliğini artırıp geliştirerek dünyaya ürün satar konumuna ulaşmıştır. Her geçen gün ekonomiye katkısı devam ederek ülkemizin önde gelen sektörlerinden biri olmuştur.

Talep tahmini uygulaması, mekanizmaların satış verilerinden yola çıkılarak yapay sinir ağlarının Matlab (R2020a) yazılımı ile gerçekleştirilmiştir. Neural Network algoritmasında eğitim ve test aşamasından sonra bir sonraki yıla ait tahmin çalışması yapılmıştır. Satış miktarı tahmininde, önceki senelerin verileri dikkate alınıp, kalitatif tahmin metotları kullanılarak gelecek senelerin satış miktarları tahminleri yapılmaktadır. Yıllık tahminler dışında dönemlik, aylık, haftalık olarak ürün bazında tahminler yapılmaktadır. Yapılan tahminlerde mevcut durum göze alınarak yapıldığından dolayı tahmin değeri ile gerçekleşen değerler her zaman birbiri ile uyumlu olmamaktadır. Bu da üretim sürecini olumsuz etkilemektedir. Geçmiş yıllara ait satış tahminleri ile YSA modeli oluşturularak gelecek yılın aylık satış miktarları tahmin edilmeye çalışılmıştır. Ürün satış miktarını etkileyen diğer faktörlerin belirlenebilmesi için literatür ve konu ile ilgili uzman görüşü dikkate alınmıştır. Bu bölümde YSA'nın uygulama aşamaları anlatılmış ve yapılan çalışma ile tahmin performansı test edilmiştir.

5.1. Talep Tahmini Probleminin Tanımlanması

Bu çalışma, mobilya sektöründe mekanizma grubunda ürün satışı gerçekleştiren firmada gerçekleştirilmiştir. Firmada üretilen ürünlerin 2020 yılı satış rakamları ve fiyat bilgileri üzerinden ABC analizi yapılmıştır. ABC analizinin sonuçları dikkate


alınarak hasılanın yaklaşık yarısına denk gelen ilk üç ürün; yatak mekanizması %30 ve kanepeler mekanizmaları %10-%8 çalışmanın sonraki aşamasında kullanılmak üzere seçilmiştir. Şirketin gizlilik politikası nedeniyle ürünlerin adı ÜrünA1, ÜrünA2, ÜrünA3 şeklinde genel ifadelerle yansıtılmıştır. Bu ilk üç ürünün ABC analizine göre yüzdesi Şekil 5.1.'de gösterilmiştir.



Şekil 5.1. ABC analizi grafiği


Literatür ve konu ile ilgili uzman görüşü dikkate alınarak yatak ve kanepeler mekanizmalarının satışında etkili olan başlıca dış faktörler olarak; mobilya sanayi üretim endeksi (TÜİK), dolar kuru (Merkez Bankası) ve ürünlerin ortalama fiyat bilgileri oluşturulacak YSA modeli için girdi olarak kullanılmıştır.

1. Sanayi Üretim Endeksi: Sanayi üretimindeki değişimler imalat sektöründeki gücü ifade etmektedir. Sanayi Üretim endeksinde mobilya sektörü dikkate alınmıştır. Şekil 5.2.'de 2017-2020 yılları arasındaki değişimi gösterilmektedir.




Şekil 5.2. Sanayi üretim endeksi değişimi 2017-2020

2. Dolar Kuru: Bir Amerikan dolarının, Türk Lirası üzerindeki değerini ifade etmektedir. Hammadde alım fiyatları dolar kuru üzerinden yapılmaktadır. Bu kuru değişimi, ürün fiyatı üzerine yansımaktadır. Bu da satışı etkilemektedir. Şekil 5.3.'de 2017-2020 yılları arasındaki aylık dolar kuru değişimi gösterilmektedir.

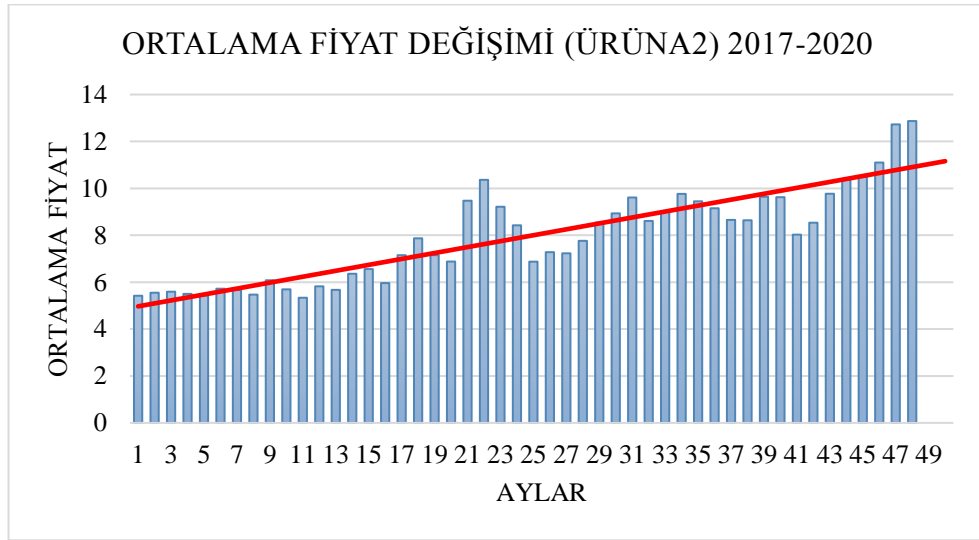


Şekil 5.3. Dolar kuru değişimi 2017-2020


3. Ortalama Fiyat: Ciroya etki eden en önemli faktörlerden biri ortalama fiyattır. Fiyattaki dalgalanmalar ürün satış miktarına etki etmektedir. Veriler aylık olarak belirlendiğinden ayın ortalama fiyatı alınmıştır. Şekil 5.4., Şekil 5.5., Şekil 5.6.'da 2017-2020 yılları arasındaki ortalama fiyat değişimleri gösterilmektedir.



Şekil 5.4. Ortalama fiyat değişimi ÜrünA1 2017-2020



Şekil 5.5. Ortalama fiyat değişimi ÜrünA2 2017-2020



Şekil 5.6. Ortalama fiyat değişimi ÜrünA3 2017-2020

5.2. Yapay Sinir Ağı Mimarisi

Yapılan bu çalışmada talep tahmininde literatürde sıkça kullanılan çok katmanlı ileri beslemeli geri yayılım algoritması ile 2017-2020 yılları arasındaki aylık veriler baz alınarak toplam 48 adet veri kullanılmıştır. Verilerin 36 adeti eğitim verisi olarak, kalan 12 adeti ağın performansını test etmek amacıyla kullanılmıştır. Tüm verilere Microsoft Excel programında normalizasyon yöntemi uygulanarak, programa normalize edilmiş şekilde aktarılmıştır. Bu çalışmadaki modelimiz, 3 girdi katmanı, 2 gizli katmanı ve 1 çıktı katmanından oluşmaktadır. Eğitime ait olan veriler ağa sunularak, ağın öğrenmesi gerçekleştirilmiştir. Öğrenme sırasındaki en uygun parametre değerlerini bulabilmek için farklı denemeler yapılmıştır.

5.3. Yapay Sinir Ağı Matlab Uygulaması

Normalizasyon, aşağıdaki denklemdeki (5.1) gibi hesaplanır.

$$X' = 2 \times \left(\frac{X - X_{min}}{X_{max} - X_{min}} \right) - 1 \quad (5.1)$$

X' Normalizasyon değeri, X gerçek değer, X_{max} en büyük değer, X_{min} en küçük değer.

Normalizasyon işleminden sonra değerler, kullanılan Matlab (R2020a) programına aktarılmıştır. Tahmin için 3 adet girdi, 1 çıktı verisi olarak model oluşturulmuştur. Satış tahmini için 3 adet girdi verisi olarak sanayi üretim endeksi, dolar kuru ve ortalama fiyat kullanılmıştır. Tahminin başarılı ve doğru bir şekilde olabilmesi için modelin eğitiminden başarılı sonuçlar elde etmemiz gerekiyor. Bunun için eğitimde önce bazı parametrelerin belirlenmesi gerekiyor. Bu parametreler deneme yanılma yolu ile gerçekleşen satış miktarı ile tahmin edilen satış miktarının oluşturduğu korelasyon değerlerinden, en iyi sonuç veren değerler seçilmiştir. Modeli en iyi şekilde oluşturan parametreler ile daha iyi bir test çalışması yapılarak tahmin sonuçlarına ulaşılabilecektir.

5.3.1. Eğitim fonksiyonunun belirlenmesi

Eğitim fonksiyonu, öğrenme performansını etkileyen en önemli parametrelerden biridir. Problemin yapısına göre eğitim fonksiyonu değişmektedir. Diğer parametre değerleri sabit tutularak program içerisinde bulunan farklı eğitim fonksiyonlarıyla her bir ürün için 14 adet deneme yapılmıştır. Nöron sayısı 10, aktivasyon fonksiyonu tanjant-sigmoid, gizli hücre sayısı 2, çevrim sayısı 5000 ve maksimum doğrulama hatası 1000 olarak sabit tutulmuştur. Gizli hücre sayısının belirlenmesinde kesinleşmiş bir yöntem bulunmamaktadır. Yapılan denemelerde en iyi korelasyon değerini veren, ürünA1 için trainscg, ürünA2 için traingd, ürünA3 için ise traingdx eğitim fonksiyonları bulunmuştur. Aşağıdaki Tablo 5.1., Tablo 5.2., Tablo 5.3.'de çıkan değerler karşılaştırılmıştır.

Tablo 5.1. ÜrünA1 için eğitim fonksiyonunun belirlenmesi

Deneme sayısı	Eğitim fonksiyonu	r
1	TRAINBFG	-0,632
2	TRAINBR	0,619
3	TRAINCGB	-0,560
4	TRAINCGF	-0,376
5	TRAINCGP	0,443
6	TRAIINGD	0,145
7	TRAIINGDM	0,334
8	TRAIINGDA	0,684
9	TRAIINGDX	-0,454
10	TRAINLM	0,524
11	TRAIINOSS	0,074
12	TRAINR	-0,488
13	TRAINRP	0,525
14	TRAINSOG	0,819

Tablo 5.2. ÜrünA2 için eğitim fonksiyonunun belirlenmesi

Deneme sayısı	Eğitim fonksiyonu	r
1	TRAINBFG	-0,552
2	TRAINBR	-0,683
3	TRAINCGB	-0,675
4	TRAINCGF	-0,032
5	TRAINCGP	-0,304
6	TRAINGD	0,732
7	TRAINGDM	-0,520
8	TRAINGDA	-0,640
9	TRAINGDX	0,530
10	TRAINLM	-0,083
11	TRAINOSS	-0,234
12	TRAINR	-0,015
13	TRAINRP	0,459
14	TRAINSCG	0,623

Tablo 5.3. ÜrünA3 için eğitim fonksiyonunun belirlenmesi

Deneme sayısı	Eğitim fonksiyonu	r
1	TRAINBFG	-0,201
2	TRAINBR	0,344
3	TRAINCGB	-0,170
4	TRAINCGF	0,667
5	TRAINCGP	-0,218
6	TRAINGD	0,232
7	TRAINGDM	0,156
8	TRAINGDA	-0,292
9	TRAINGDX	0,716
10	TRAINLM	-0,043
11	TRAINOSS	0,101
12	TRAINR	0,122

Tablo 5.3. (Devamı)

Deneme sayısı	Eğitim fonksiyonu	r
13	TRAINRP	0,001
14	TRAINSCG	0,352

5.3.2. Nöron sayısının belirlenmesi

Bir diğer önemli parametre ise katmanlardaki nöron sayısının belirlenmesidir. Nöron sayısındaki değişimler modeli etkilemektedir. Bu sayının belirlenmesi için de deneme yanılma yöntemi uygulanmıştır. 1-20 arasındaki değerler verilerek en uygun değer bulunmaya çalışılmıştır. Denemeler; eğitim fonksiyonu her bir ürünün belirlenmiş olan fonksiyonu, aktivasyon fonksiyonu tanjant-sigmoid (tansig), çevrim sayısı 5000 ve maksimum doğrulama hatası 1000 alınarak gerçekleştirilmiştir. Bu değerler sabit tutularak 1-20 arasındaki nöron sayıları denenmiştir. Her bir ürün için deneme sonuçları Tablo 5.4., Tablo 5.5., Tablo 5.6.'da gösterilmektedir.

Tablo 5.4. ÜrünA1 için nöron sayısının belirlenmesi

Deneme sayısı	Nöron sayısı	r
1	1	0,682
2	2	-0,188
3	3	0,304
4	4	-0,238
5	5	-0,094
6	6	-0,013
7	7	0,291
8	8	0,680
9	9	0,778
10	10	0,819
11	11	-0,457
12	12	0,571
13	13	0,790

Tablo 5.4. (Devamı)

Deneme sayısı	Nöron sayısı	<i>r</i>
14	14	0,695
15	15	0,019
16	16	0,805
17	17	-0,438
18	18	-0,073
19	19	0,349
20	20	0,326

Tablo 5.5. ÜrünA2 için nöron sayısının belirlenmesi

Deneme sayısı	Nöron sayısı	<i>r</i>
1	1	-0,001
2	2	-0,445
3	3	0,628
4	4	0,668
5	5	0,139
6	6	-0,612
7	7	-0,693
8	8	-0,759
9	9	0,652
10	10	0,732
11	11	-0,521
12	12	-0,683
13	13	-0,558
14	14	-0,003
15	15	0,136
16	16	-0,552
17	17	0,596
18	18	-0,042

Tablo 5.5. (Devamı)

Deneme sayısı	Nöron sayısı	<i>r</i>
19	19	-0,090
20	20	0,003

Tablo 5.6. ÜrünA3 için nöron sayısının belirlenmesi

Deneme sayısı	Nöron sayısı	<i>r</i>
1	1	0,176
2	2	0,724
3	3	0,069
4	4	0,338
5	5	0,104
6	6	-0,281
7	7	-0,070
8	8	0,290
9	9	-0,725
10	10	0,716
11	11	-0,498
12	12	0,156
13	13	0,584
14	14	-0,152
15	15	0,056
16	16	-0,510
17	17	0,375
18	18	0,210
19	19	0,317
20	20	-0,105

5.3.3. Aktivasyon fonksiyonunun belirlenmesi

Aktivasyon fonksiyonları, toplama fonksiyonundan gelen bilgiyi işleyerek çıktı katmanına iletir. YSA modelleri için en sık kullanılan bu üç aktivasyon fonksiyonu LOGSIG, TANSIG ve PURELIN fonksiyonlarıdır. Bu fonksiyonun belirlenmesi için deneme yanılma yöntemi ile çevrim sayısı 5000 ve maksimum doğrulama hatası 1000 olarak denemeler yapılmıştır. ÜrünA1 için yapılan denemelerde nöron sayısı 10 ile 13 ve 16 değerleri de kullanılmıştır. Nöron sayısı belirlenirken bu üçünün birbirine yakın değerlerde korelasyon değeri verdiği gözlenmiştir. Bu sebeple üç farklı nöron sayısı için aktivasyon fonksiyonu denemeleri yapılmıştır. Üç ürün için yapılan deneme sonuçları Tablo 5.7., Tablo 5.8., Tablo 5.9.'da gösterilmektedir.

Tablo 5.7. ÜrünA1 için aktivasyon fonksiyonunun belirlenmesi

Deneme sayısı	Nöron sayısı	Aktivasyon fonksiyonu	r
1	10	LOGSIG	-0,794
2	10	TANSIG	0,819
3	10	PURELIN	0,549
4	13	LOGSIG	0,654
5	13	TANSIG	0,790
6	13	PURELIN	0,741
7	16	LOGSIG	-0,149
8	16	TANSIG	0,805
9	16	PURELIN	0,527

Tablo 5.8. ÜrünA2 için aktivasyon fonksiyonunun belirlenmesi

Deneme sayısı	Nöron sayısı	Aktivasyon fonksiyonu	r
1	8	LOGSIG	-0,105
2	8	TANSIG	-0,759
3	8	PURELIN	-0,615

Tablo 5.9. ÜrünA3 için aktivasyon fonksiyonunun belirlenmesi

Deneme sayısı	Nöron sayısı	Aktivasyon fonksiyonu	r
1	9	LOGSİG	0,304
2	9	TANSİG	-0,725
3	9	PURELIN	0,433

5.3.4. Çevrim sayısının belirlenmesi

Eğitim fonksiyonu, nöron sayısı, aktivasyon fonksiyonunun belirlenmesinden sonra sıra çevrim sayısının belirlenmesine gelmiştir. Yine bu parametre için de deneme yanılma yöntemi kullanılmıştır. Belirli değerler verilerek en uygun sonuç elde edilmeye çalışılmıştır. Her ürün için bulunan eğitim fonksiyonu, nöron sayısı, aktivasyon fonksiyonu değerleri kullanılarak, maksimum doğrulama hatası 1000 olarak sabit tutulup belirli çevrim sayısı değerlerinde denemeler yapılmıştır. Bulunan değerler Tablo 5.10., Tablo 5.11., Tablo 5.12’de gösterilmektedir.

Tablo 5.10. ÜrünA1 için çevrim sayısının belirlenmesi

Deneme sayısı	Çevrim sayısı	r
1	500	0,272
2	1000	0,728
3	1500	0,403
4	2000	0,365
5	2500	0,861
6	3000	-0,490
7	3500	0,780
8	4000	0,642
9	4500	-0,665
10	5000	0,819

Tablo 5.11. ÜrünA2 için çevrim sayısının belirlenmesi

Deneme sayısı	Çevrim sayısı	r
1	500	0,059
2	1000	-0,815
3	1500	0,434
4	2000	-0,102
5	2500	-0,016
6	3000	0,232
7	3500	0,152
8	4000	0,440
9	4500	0,530
10	5000	-0,759

Tablo 5.12. ÜrünA3 için çevrim sayısının belirlenmesi

Deneme sayısı	Çevrim sayısı	r
1	500	-0,636
2	1000	-0,602
3	1500	0,633
4	2000	-0,729
5	2500	-0,350
6	3000	0,530
7	3500	0,362
8	4000	-0,147
9	4500	-0,415
10	5000	-0,725

5.3.5. Maksimum doğrulama hatasının belirlenmesi

Eğitim fonksiyonu, nöron sayısı, aktivasyon fonksiyonu, çevrim sayısının belirlenmesinden sonra uygun maksimum doğrulama hatasının (`max_fail`) belirlenmesi için denemeler yapılmıştır. Her ürün için 10'ar adet deneme yapılarak

en uygun korelasyon deęerini veren maksimum doęrulama hatası seęilmiřtir. Belirlenen eęitim fonksiyonu, nron sayısı, aktivasyon fonksiyonu, evrim sayısı deęerleri sabit tutularak en uygun korelasyon deęerini veren belirlenmiřtir. Deneme sonuları Tablo 5.13., Tablo 5.14., Tablo 5.15.'de gsterilmektedir.

Tablo 5.13. rnA1 iin maksimum doęrulama hatasının belirlenmesi

Deneme sayısı	Max_fail	r
1	500	-0,528
2	1000	0,861
3	1500	-0,770
4	2000	0,458
5	2500	0,180
6	3000	-0,064
7	3500	-0,275
8	4000	-0,639
9	4500	0,399
10	5000	0,787

Tablo 5.14. rnA2 iin maksimum doęrulama hatasının belirlenmesi

Deneme sayısı	Max_fail	r
1	500	0,677
2	1000	-0,815
3	1500	-0,686
4	2000	-0,637
5	2500	-0,303
6	3000	0,119
7	3500	0,515
8	4000	-0,368
9	4500	-0,668
10	5000	-0,615

Tablo 5.15. ÜrünA3 için maksimum doğrulama hatasının belirlenmesi

Deneme sayısı	Max_fail	r
1	500	0,137
2	1000	-0,729
3	1500	0,437
4	2000	0,846
5	2500	0,116
6	3000	-0,589
7	3500	-0,577
8	4000	-0,583
9	4500	0,634
10	5000	-0,555

5.3.6. Ağ türünün belirlenmesi

Eğitim fonksiyonu, nöron sayısı, aktivasyon fonksiyonu, çevrim sayısı, maksimum doğrulama hatasının belirlenmesinden sonra uygun ağ türünün belirlenmesi için denemeler yapılmıştır. Her ürün için 5'er adet deneme yapılarak en uygun korelasyon değerini veren ağ türü seçilmiştir. Deneme sonuçları Tablo 5.16., Tablo 5.17., Tablo 5.18.'de gösterilmektedir.

Tablo 5.16. ÜrünA1 için ağ türünün belirlenmesi

Deneme sayısı	Ağ türü	r
1	Cascade-forward backprop	0,412
2	Feed- forward backprop	-0,861
3	Generalized regression	0,588
4	Layer recurrent	-0,620
5	NARX	-0,380

Tablo 5.17. ÜrünA2 için ağ türünün belirlenmesi

Deneme sayısı	Ağ türü	r
1	Cascade-forward backprop	-0,526
2	Feed- forward backprop	-0,815
3	Generalized regression	-0,543
4	Layer recurrent	-0,216
5	NARX	0,477

Tablo 5.18. ÜrünA3 için ağ türünün belirlenmesi

Deneme sayısı	Ağ türü	r
1	Cascade-forward backprop	-0,446
2	Feed- forward backprop	-0,846
3	Generalized regression	-0,029
4	Layer recurrent	0,320
5	NARX	0,022

Ürünler için belirlenmiş olan en uygun parametre değerleri Tablo 5.19'da gösterilmektedir.


Tablo 5.19. Ürünlerin en uygun parametre değerleri

Ürün	Eğitim fonksiyonu	Nöron sayısı	Aktivasyon fonksiyonu	Çevrim sayısı	Max_fail	Ağ türü
ÜrünA1	TRAINSCG	10	TANSIG	2500	1000	Feed- forward backprop
ÜrünA2	TRAINGD	8	TANSIG	1000	1000	Feed- forward backprop
ÜrünA3	TRAINGDX	9	TANSIG	2000	2000	Feed- forward backprop

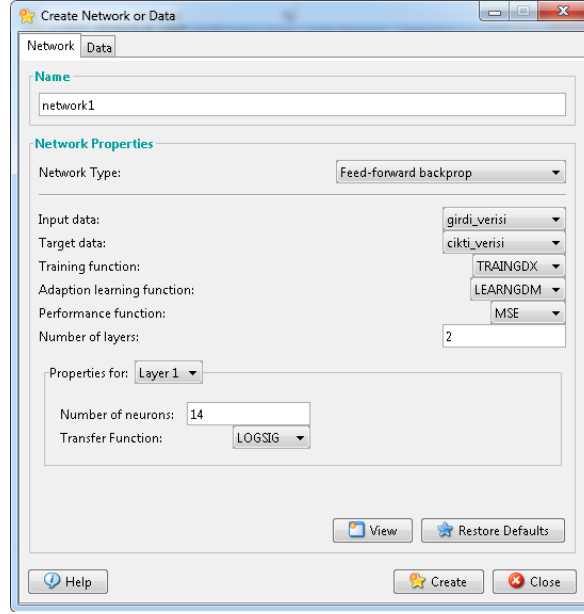
5.4. Yapay Sinir Ağının Eğitilmesi

Yapay sinir ağının eğitilmesi için Matlab (R2020a) programının Neural Network uygulaması kullanılmıştır. Microsoft Excel programında eğitim ve test için normalize edilmiş olan verilerin programa girişi gerçekleştirilir. Bu verilerin 36 adeti eğitim

verisi, 12 adeti test verisi olmak üzere ayrılmıştır. Normalize edilmiş olan verilerin import data kısmından programa girişi yapılır. Daha sonra veriler transpoze edilir ve Şekil 5.7.'de olduğu gibi çıkan ekrana input ve output verileri tanımlanır. Şekil 5.8.'deki ekrana parametre girişleri yapılır. Feed-forward backprop olan ileri beslemeli-geri yayımlı ağın girdi, çıktı verileri, öğrenme ve performans fonksiyonları, katman sayısı, nöron sayısı, gizli hücre sayısı ve aktivasyon fonksiyonu girişleri yapılır. Bütün bu parametrelerin programa girilmesinden sonra ağ oluşturma işlemi başarıyla gerçekleştirilmiş olur.




Şekil 5.7. Girdi ve çıktı değerlerinin sınıflandırılması




Şekil 5.8. Değişkenlere ait parametreler

Şekil 5.9.'da ÜrünA1 için oluşturulmuş olan ağın yapısına ulaşılır. Girdi katman sayısı 3, çıktı katman sayısı 1 ve nöron sayısı 10 olan ağ oluşturulmuştur.




Şekil 5.9. ÜrünA1 için yapay sinir ağı modeli

Şekil 5.10.'da ÜrünA2 için oluşturulmuş olan ağın yapısına ulaşılır. Girdi katman sayısı 3, çıktı katman sayısı 1 ve nöron sayısı 8 olan ağ oluşturulmuştur.



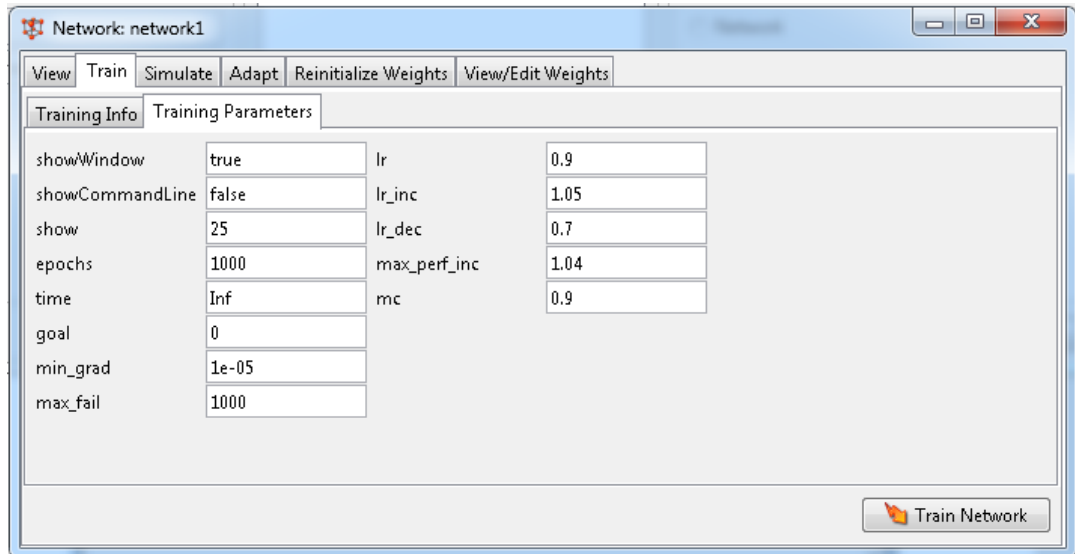
Şekil 5.10. ÜrünA2 için yapay sinir ağı modeli

Şekil 5.11.'de ÜrünA3 için oluşturulmuş olan ağın yapısına ulaşılır. Girdi katman sayısı 3, çıktı katman sayısı 1 ve nöron sayısı 9 olan ağ oluşturulmuştur.



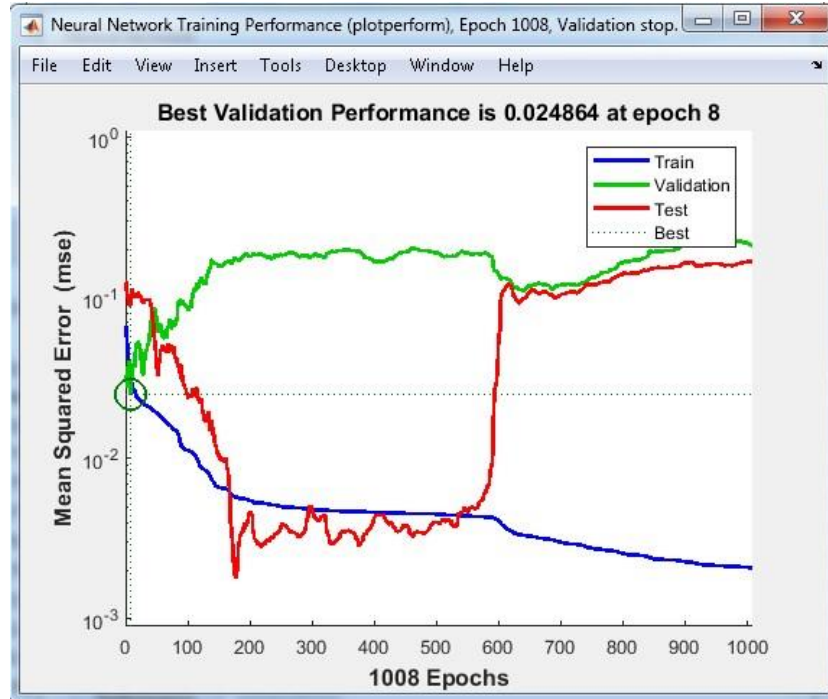
Şekil 5.11. ÜrünA3 için yapay sinir ağı modeli

Ağ oluşumundan sonra eğitim için gerekli parametrelerin girilmesi gerekmektedir. Şekil 5.12.'deki çevrim sayısı ve maksimum doğrulama değerlerinin programa girişi yapılır.

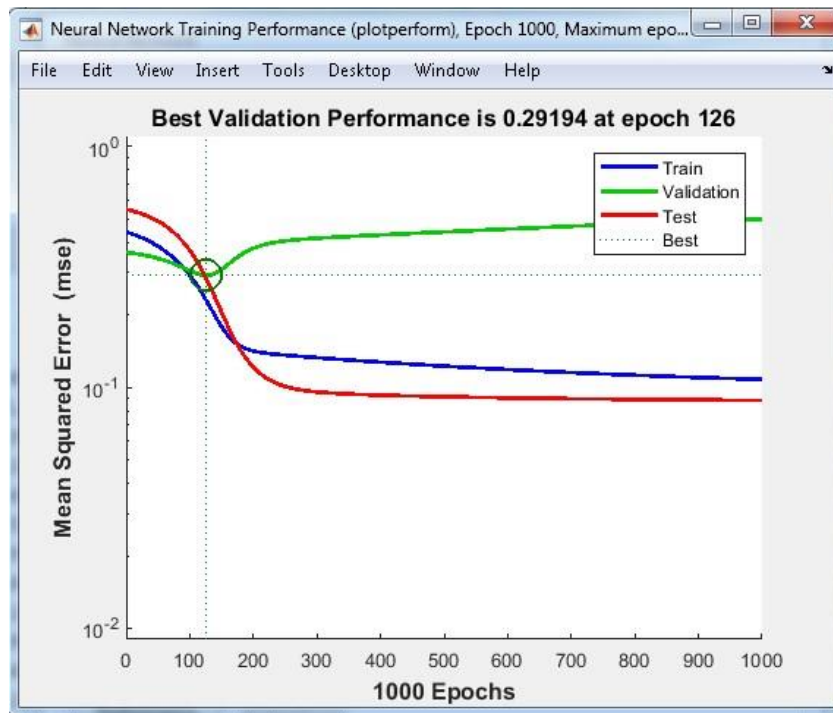


Şekil 5.12. Yapay sinir ağı eğitim ekranı


Bütün değerlerin girişleri yapıldıktan sonra ağ eğitime hazırdır. Ağ eğitilir. Ve performans grafiği Şekil 5.13., Şekil 5.14, Şekil 5.15.'de gösterilmektedir. Buna göre model en iyi performansa ulaşmıştır. Her üç ürün için ağın eğitimi başarılı bir şekilde tamamlanmıştır.



Şekil 5.13. ÜrünA1 için performans grafiği



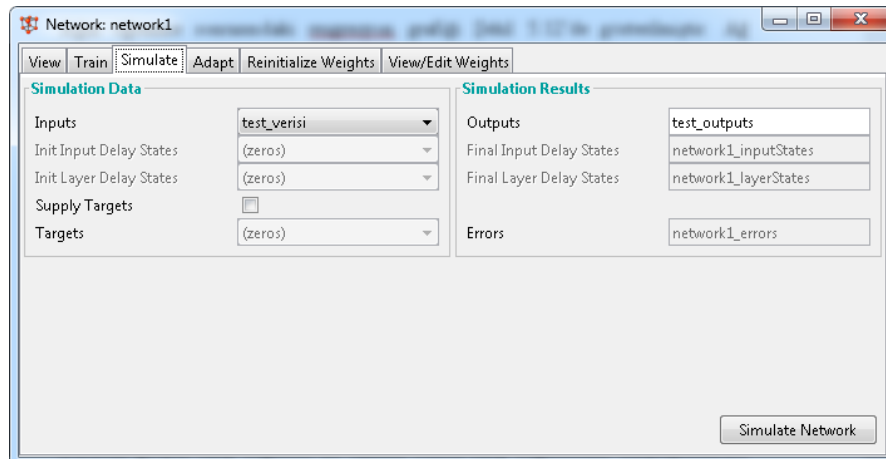
Şekil 5.14. ÜrünA2 için performans grafiği



Şekil 5.15. ÜrünA3 için performans grafiği

5.5. Sonuçların Test Edilmesi

Ağın eğitimi 2017-2019 yılları arasındaki 36 adet veri ile tamamlandıktan sonra ağın yeni veriler ile test aşamasına geçilir. Bunun için 2020 yılına ait olan 12 adet veri ile çalışma yapılır. 2020 yılına ait satış miktarları için Şekil 5.16.'da çıkan ekranda test girdi verilerinin girişi yapılır. Daha sonra çıktı verilerinin “Workspace” ekranına gelmesi sağlanır. Buradan gerçek satış değerleri ile tahmin edilen satış değerlerinin karşılaştırılması yapılır. Tablo 5.20.'de bu karşılaştırma inceleyebilir.



Şekil 5.16. Matlab YSA test ekranı

Çalışma, en iyi korelasyon sonucunu veren değerler seçilerek gerçekleştirilmiştir. Gerçekleşen 2020 yılı değerleri ile tahmin edilen 2020 yılı değerleri arasında üç ürün için 0,86, 0,82, 0,85 korelasyon değerleri elde edilmiştir. Tablo 5.17.'de tahmin sonuçları gösterilmektedir.

Tablo 5.20. YSA sonuçları

Ürün	Test korelasyon değeri
ÜrünA1	0,86
ÜrünA2	0,82
ÜrünA3	0,85

Tablo 5.21.'de korelasyon değerlerinin oldukça pozitif değer aralığında çıktığı gözlemlenmiştir. Böylelikle modelin iyi bir tahmin sınıfında olduğu sonucuna varılmıştır.

Tablo 5.21. Korelasyon katsayısı sınıfları (Şen, 2017)

Sayısal değer aralıkları	Yorumlar
$P_p = -1,0$	Tamamen negatif bağımlılık
$-1,0 < P_p < -0,9$	Güçlü negatif bağımlılık
$-0,9 < P_p < -0,7$	Oldukça negatif bağımlılık
$-0,7 < P_p < -0,5$	Zayıf negatif bağımlılık
$-0,5 < P_p < -0,3$	Çok zayıf negatif bağımlılık
$-0,3 < P_p < -0,1$	Önemsiz negatif bağımlılık
$P_p = 0$	Tamamen bağımsız
$0,1 < P_p < 0,3$	Önemsiz pozitif bağımlılık
$0,3 < P_p < 0,5$	Çok zayıf pozitif bağımlılık
$0,5 < P_p < 0,7$	Zayıf pozitif bağımlılık
$0,7 < P_p < 0,9$	Oldukça pozitif bağımlılık
$0,9 < P_p < 1,0$	Güçlü pozitif bağımlılık
$P_p = 1,0$	Tamamen pozitif bağımlılık

BÖLÜM 6. SONUÇ VE DEĞERLENDİRME

Artan rekabetle şirketler rakiplerinden farklı olabilmek ve ayakta kalabilmek için gelecekle ilgili doğru adımlar atmalıdırlar. Bunun için üretimlerinde kaynakların doğru kullanımı, istenilen zamanda istenilen miktar kadar üretim yapılıp müşteri memnuniyetinin arttırmak için gelecek tahminleri gerçeğe yakın olmalıdır. Günümüze en yaygın kullanılan tahmin yöntemi yapay sinir ağları modelidir. Birçok alanda kullanılan ve gerçeğe yakın sonuçlar vermesinden dolayı en çok tercih edilen yöntem olmuştur.

Çalışmada, mobilya sektöründe mekanizma üretiminde yurtiçi ve yurtdışına hizmet veren bir firmanın, 2017-2019 yılı verileri kullanılarak YSA ile tahmini ele alınmıştır.

Çalışmada ilk olarak ABC analizi ile hasılda %30, %10, %8'lik değerler ile ilk 3 sırada yer alan ürünler belirlenmiştir. Bu ürünler için uzman görüşler ve literatürdeki çalışmalar dikkate alınarak mobilya sektörü sanayi üretim endeksi, dolar kuru ve fiyat girdi değişkenleri olarak kullanılmıştır. Sanayi üretim endeksi TÜİK internet sitesinden, dolar kuru ise Merkez Bankasının internet sitesinden alınmıştır. Fiyat ve satış miktarları şirket içerisinden talep edilmiştir. Çalışmada 2017-2020 yılları arasındaki 48 aylık veri kullanılmıştır. Bu 48 aylık verinin 36 aylık olanı ağın eğitimi için, kalan 12 aylık veri ise ağın testi için 2020 yılının satış tahmini için kullanılmıştır. Tüm veriler öncelikli olarak normalize edilerek [-1, +1] aralığına çevrilmiştir. Daha sonra verilerin ağa girişi gerçekleştirilmiştir. Ağın en iyi sonucu verebilmesi için gerekli parametre değerlerinin belirlenmesi yapılmıştır. Bu parametre değerlerinin belirlenmesinde deneme yanılma yöntemi kullanılmıştır. Ağın

eđitimi tamamlandıktan sonra, ađa daha nce tanıtılmayan 2020 yılı girdi verileri iin bir tahmin yapması beklenmiřtir.

alıřmanın yapıldıđı dnemde dnya genelinde yayılan bir virs salgını ortaya ıkmıřtır. Trkiye’de dahil olmak zere tm lkeler bu salgından etkilenmiřtir. Salgın sebebi ile karantina dnemleri yařanmıř ve sektrlerde alıřmalar azaltılıp geici sre durdurularak retimde dřřler olmuřtur. Tablo 5.17.’deki sonular incelendiđinde bu beklenmedik virs salgınına rađmen YSA ile firmanın kritik nem grubuna sahip rnleri iin bařarılı sonular elde edilebileceđi grlmektedir.

alıřma bu sektrdeki diđer rnler iinde geniřletilebilir. Farklı yapay zeka teknikleri denenerek sonular karřılařtırılabilir.

KAYNAKLAR

- Abellatief, M., Shaaban, M. E. & Abu-Raya, K. A., 2019. Egyptian Case Study-Sales forecasting model for automotive section. Egypt, Institute of Electrical and Electronics Engineers.
- Akpınar, M., 2017. İstatistik ve yapay zeka teknikleri ile enerji tüketiminin tahmini: Sakarya doğal gaz tüketiminin uygulaması. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Ve Bilişim Mühendisliği Bölümü, Doktora Tezi.
- Amalnick, M. S., Habibifar, N. & Hamid, M., 2020. An intelligent algorithm for final product demand forecasting in pharmaceutical units. International Journal of System Assurance Engineering and Management, Issue 11, pp. 481-493.
- Aydın, D., 2012. Yapay sinir ağları yardımı ile talep tahmin analizi ve deniz taşımacılığı sektöründe bir uygulama. Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, Yöneyler Araştırması Bilim Dalı, Yüksek Lisans Tezi.
- Calp, M., 2019. İşletmeler için personel yemek talep miktarının yapay sinir ağları kullanılarak tahmin edilmesi. Journal of politechnic, 22(3), pp. 675-686.
- Dick, S., 2019. Artificial Intelligence. Harvard Data Science Review, 1(1), pp. 1-8.
- Doğan, H. B., 2019. Beklenmedik uçak yönlendirmelerini azaltma: zaman serisi analizi ve yapay sinir ağları ile modelleme. TOBB Ekonomi Ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Elmas, Ç., 2021. Yapay Zeka Uygulamaları. 5. Seçkin.
- Eren, U. & Satoğlu, Ş. I., 2017. Perakende giyim sektöründe yapay sinir ağları ile talep tahmini. İstanbul.
- Gürsoy, A., 2012. Yapay sinir ağları yaklaşımıyla lastik kalıbı maliyetlerinin tahmin edilmesi. Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Hazır, E., Koç, K. H. & Esnaf, Ş., 2015. Türkiye mobilya satış değerlerinin örnek bir yapay zeka uygulaması ile tahmini. Konya, 3. Ulusal Mobilya Kongresi(UMK 2015).
- İmren, E., Kaygın, B. & Karayılmazlar, S., 2021. Türkiye mobilya sektörü dış ticaret verilerinin yapay sinir ağları ile değerlendirilmesi. Bartın Orman Fakültesi Dergisi, 23(3), pp. 906-916.

- Kargı, V. S., 2015. Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama, Ekin Kitabevi.
- Kargı, V. S. A. & Öztürk, A., 2013. Yapay sinir ağ modelleri ve bir tekstil firmasında uygulama. Bursa Uludağ üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı, Doktora Tezi.
- Keskenler, M. F. & Keskenler, E. F., 2017. Geçmişten günümüze yapay sinir ağları ve tarihçesi. Takvim-i Vekayi, 5(2), pp. 8-18.
- Klir, G. J. & Yunan, B., 1995. Fuzzy Sets and Fuzzy Logic Theory and Applications. New Jersey: Prentice Hall.
- Kobu, B., 2008. Üretim Yönetimi. 14. dü. İstanbul: Beta.
- Korkut, D., 2019. Yapay sinir ağları yöntemi ile talep tahmini ve ayakkabı sektörüne uygulaması. Ankara Hacı Bayram Veli Üniversitesi, Lisansüstü Eğitim Enstitüsü, Ekonometri Anabilim Dalı, Yüksek Lisans Tezi.
- Kriesel, D., 2007. A Brief Introduction to Neural Networks. www.dkriesel.com
- Kurnaz, K., 2014. Yapay sinir ağları ile makine öğrenmesi uygulaması. <http://kubrakurnaz34.blogspot.com>
- Kurt, R., Karayılmazlar, S., İmren, E. & Çabuk, Y., 2017. Yapay sinir ağları ile öngörü modellenmesi: Türkiye kağıt-karton sanayi örneği. Bartın Orman Fakültesi Dergisi, 19(2), pp. 99-106.
- Lin, Y.-F., Cheng, C.-S. & Chen, Y.-C., 2021. Sales forecasting using ANNs or RNNs - A case study of freeway service station in Taiwan. Taiwan, Institute of Electrical and Electronics Engineers.
- Mahbub, N., Paul, S. K. & Azeem, A., 2013. A neural approach to product demand forecasting. Int. J. Industrial and Systems Engineering, 15(1), pp. 1-18.
- Nasuhoğlu, H., 2019. Eczacılık sektöründe yapay sinir ağları ve zaman serileri analizi ile talep tahmini. Maltepe Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Olgun, S., 2009. Tedarik zinciri yönetiminde talep tahmini yöntemleri ve yapay zeka tabanlı bir talep tahmini modelinin uygulanması. İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Öztemel, E., 2016. Yapay Sinir Ağları. 4. dü. İstanbul: Papatya Yayıncılık.
- Öztürk, K. & Şahin, M. E., 2018. Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. Takvim-i Vekayi, 6(2), pp. 25-36.
- Sarı, M., 2016. Yapay sinir ağları ve bir otomotiv firmasında satış talep tahmini uygulaması. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Serttaş, Z. S., 2011. Türkiye'de perakene sektörüne talebi etkileyen etmenler ve yapay sinir ağlarıyla talep tahmini uygulaması. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Şen, Z., 2017. Innovative Trend Methodologies in Science and Engineering. New York: Springer International Publishing, pp. 1-349.

- Topal, İ., 2019. Çevrimiçi tüketici bütünleşmesi ve arama motoru verileri kullanılarak yapay sinir ağları ile otomobil satış tahmini. Nevşehir Hacı Bektaş Veli Üniversitesi SBE Dergisi, 9(2), pp. 534-551.
- Türk, E. & Kiani, F., 2019. Yapay sinir ağları ile talep tahmini yapma: Beyaz eşya üretim planlaması için YSA uygulaması. İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 1(1).
- Yangın, A. & Zontul, M., 2017. Yapay sinir ağı tekniklerim kullanılarak eğitim yayıncılığı sektöründe veri madenciliği. Aueum Mühendislik Sistemleri ve Mimarlık Dergisi, 1(2), pp. 1-15.
- Yanık, E., 2019. İş makineleri sektöründe yapay sinir ağları ile talep tahmini uygulaması. Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Yazıcıoğlu, N., 2010. Yapay zeka ile talep tahmini. Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Yücesan, M., Gül, M. & Çelik, E., 2017. Application of artificial neural networks using Bayesian training rule in sales forecasting for furniture industry. Drvna Industrija, 68(3), pp. 219-228.
- Yücesan, M., Gül, M. & Çelik, E., 2018. Performance comparison between ARIMAX, ANN and ARIMAX-ANN hybridization in sales forecasting for furniture industry. Drvna Industrija, 69(4), pp. 357-370.
- Yücesoy, M., 2011. Temizlik kağıtları sektöründe yapay sinir ağları ile talep tahmini. İstanbul Teknik Üniversitesi. Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- www.tuik.gov.tr, Erişim Tarihi: 15.05.2021
- www.tcmb.gov.tr, Erişim Tarihi: 15.05.2021

ÖZGEÇMİŞ

Adı Soyadı : Burçin SALTÖURK

ÖÖRENİM DURUMU

Derece	Eđitim Birimi	Mezuniyet Yılı
Yüksek Lisans	Sakarya Üniversitesi / Fen Bilimleri Enstitüsü / Mühendislik Yönetimi	Devam ediyor
Lisans	Gazi Üniversitesi / Mühendislik Fakültesi / Endüstri Mühendisliđi	2012
Lise	İzzet Baysal Anadolu Lisesi	2007

İŞ DENEYİMİ

Yıl	Yer	Görev
2013-Halen	Eksan Mekanizma A.Ş.	Üretim Planlama Şefi

YABANCI DİL

İngilizce