

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

**YAPAY SİNİR AĞI METODU İLE BİR TEKSTİL
FİRMASINDA HAMMADDE SİPARİŞİ İÇİN TALEP
TAHMİNİ UYGULAMASI**

YÜKSEK LİSANS TEZİ

Büşra ENGİN

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Tez Danışmanı : Dr.Öğr.Üyesi Tülay KORKUSUZ POLAT

Ocak 2022

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

**YAPAY SİNİR AĞI METODU İLE BİR TEKSTİL
FİRMASINDA HAMMADDE SİPARİŞİ İÇİN TALEP
TAHMİNİ UYGULAMASI**

YÜKSEK LİSANS TEZİ

Büşra ENGİN

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Bu tez 10.01.2022 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.

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.

İmza (Bu satır çıktı almadan önce silinecektir.)

Büşra ENGİN

10.01.2022

TEŞEKKÜR

Yüksek lisans eğitimim boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, değerli danışman hocam Dr.Öğr.Üyesi Tülay KORKUSUZ POLAT’a, Prof.Dr.Harun Reşit YAZGAN’a, Dr.Öğr.Üy.Buket KARATOP’a ve Arş.Gör.Serap ERCAN CÖMERT’e en kalbi duygularıyla şükranlarımı sunarım.

Her zaman yanımda olan, beni destekleyen, benimle gurur duyan annem ve babam Suzan-Süleyman ENGİN’e, kardeşim Yunus Emre ENGİN’e, abim ve eşi Yusuf - Kader ENGİN, her zaman yol gösterici olan değerli ablam/abim Müjgan-İsmail EVREN’e, sevgili yeğenlerim Zehra ve Öykü’ye en kalbi duygularıyla teşekkür ederim.

Çalışma hayatımda her daim yol gösterici ve destek olan değerli yöneticim Rahşan ÖZHAN SEZER’e teşekkürü bir borç bilirim.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	v
TABLolar LİSTESİ	vi
ÖZET	vii
SUMMARY	vii
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
KAYNAK ARAŞTIRMASI	4
2.1. Literatürde Yer Alan Talep Tahmini Çalışmaları.....	4
BÖLÜM 3.	
MATERYAL VE YÖNTEM	9
3.1. Materyal	9
3.2. Yapay Sinir Ağları.....	9
3.2.1. Biyolojik sinir hücresi.....	11
3.2.2. Yapay sinir hücresi.....	11
3.2.3. Yapay sinir ağı.....	12
3.2.4. Yapay sinir ağı sınıflandırılması.....	14
3.2.4.1. Katmanlarına göre yapay sinir ağları.....	14
3.2.4.2. Yapılarına göre yapay sinir ağları.....	14

3.2.4.3. Öğrenme yöntemlerine göre yapay sinir ağları.....	14
--	----

BÖLÜM 4.

ARAŞTIRMA BULGULARI	16
4.1. Tekstil Sektöründe Tedarik Zinciri Yönetimi.....	16
4.2. Kumaş Üretimi ve Tedarik Yönetimi.....	19
4.3. Tedarik Zinciri Yönetiminde Kumaş Talep Tahmininin Önemi.....	20
4.4. Problemin Tanımlanması.....	21
4.5. Verilerin Normalizasyonu.....	26
4.6. Yapay Sinir Ağı MATLAB Uygulaması.....	30
4.6.1. Öğrenme katsayısı ve momentum katsayısının belirlenmesi	31
4.6.2. Nöron sayısının belirlenmesi.....	32
4.6.3. Yapay sinir ağının eğitilmesi.....	33
4.6.4. Yapay sinir ağının test edilmesi.....	36

BÖLÜM 5.

TARTIŞMA VE SONUÇ	38
KAYNAKLAR	40
ÖZGEÇMİŞ	44

SİMGELER VE KISALTMALAR LİSTESİ

AI	: Yapay Zeka
AMR	: Uyarlamalı Mutasyon Hızı
ANN	: Yapay Sinir Ağı Modeli
ELM	: Aşırı Öğrenme Makinesi
GA	: Genetik Algoritmalar
KNN	: K-Nearest Neighbour
LRA	: Lineer Regresyon Analizi
LSTM	: Uzun Kısa Süreli Bellek
LSTM NN	: Uzun Kısa Süreli Bellek Sinir Ağları
RF	: Random Forest
SVM	: Destek Vektör Makineleri
SVR	: Destek Vektör Regresyonu
YSA	: Yapay Sinir Ağı

ŞEKİLLER LİSTESİ

Şekil 3.1. Biyolojik Sinir Hücresi.....	11
Şekil 3.2. Yapay Sinir Ağı Yapısı	12
Şekil 3.3. Yapay Sinir Ağı Yapısı ve Katmanlar.....	13
Şekil 4.1. Tekstil Sektöründe Ürün Hayat Döngüsü	18
Şekil 4.2. Kumaş Üretim Safhaları	19
Şekil 4.3. Min Max Min Max Normalizasyon Yöntemi ile YSA Performansı	29
Şekil 4.4. D-Min Max Normalizasyon Yöntemiyle YSA Performansı	30
Şekil 4.5. Matlab YSA Oluşturulma Ekranı	34
Şekil 4.6. Yapay Sinir Ağı Modeli.....	34
Şekil 4.7. Yapay Sinir Ağı Eğitim Ekranı	35
Şekil 4.8. YSA Regrasyon Grafiği	35
Şekil 4.9. Matlab Test Verisi Yükleme Ekran Görüntüsü	36

TABLolar LİSTESİ

Tablo 3.1. Biyolojik Sinir Hücresi ile Yapay Sinir Ağının Karşılaştırılması.....	12
Tablo 4.1. Kumaş Türü ve Kodu	22
Tablo 4.2. Kumaş Özelliği ve Kodu	22
Tablo 4.3. Boya Cinsi ve Kodu	22
Tablo 4.4. Elyaf Karışımı ve Kodu	23
Tablo 4.5. İplik Numarası ve Kodu	25
Tablo 4.6. Veri Seti Max-Min Değerleri	26
Tablo 4.7. Min Max Normalizasyon Yöntemiyle Normalize Edilmiş Örnek Veri	27
Tablo 4.8. D-Min Max Yöntemiyle Normalize Edilmiş Örnek Veri	28
Tablo 4.9. Öğrenme Katsayısı Denemelerindeki YSA Performansı	31
Tablo 4.10. Momentum Katsayısı Denemelerindeki YSA Performansı	32
Tablo 4.11. Nöron Sayısı Denemelerindeki YSA Performansı	32
Tablo 4.12. Tahmini ve Gerçekleşen Kumaş Sipariş Verileri ve Hata Oranları...	37

ÖZET

Anahtar kelimeler: Yapay sinir ağı, talep tahmini, tekstil

Bu çalışmada, bir tekstil firmasının kumaş sipariş miktarını geçmiş verilere dayanarak yapay sinir ağı yöntemiyle talep tahmini çalışması ile kumaş sipariş miktarının tahmin edilmesi amaçlanmaktadır. Şirket için büyük öneme sahip talep tahmini stratejik planlamalarda önemli girdi sağlamaktadır. Geleceği doğru tahmin ederek, doğru stratejik planların oluşturulması şirketlerin hedeflerine ulaşmalarını sağlamaktadır. Kumaş sipariş tahmini ile gelecek yıl kullanılacak kumaş miktarına göre tedarikçi kapasite planı yapılabilecektir.

Kumaş talep tahmininde kumaş türü, kumaş özelliği, boya cinsi, elyaf karışı, iplik numarası, özel gün bilgisi, tüketici güven endeksi, ekonomik güven endeksi ve tüketici fiyat endeksi dikkate alınarak Matlab2018b yazılımı Neural Network Toolbox'ı ile Yapay Sinir Ağı metoduyla talep tahmini yapılmıştır.

Verilerin normalizasyonunda D-Min-Max ve Min-Max normalizasyon metodları kullanılarak yapay sinir ağının performansı karşılaştırılmıştır. Min-Max normalizasyon yöntemi ile veriler 0-1 arasına indirgenerek daha başarılı performans verdiği gözlemlenmiştir.

Yapay sinir ağı modeli oluşturulurken öğrenme katsayısı, momentum katsayısı, nöron sayısı için çeşitli denemeler yapılarak %98,59 performansını veren ysa modeli tahminleme çalışmasında kullanılmıştır. Yapay sinir ağı modeli MSE değeri 0,001756 ve MAPE değeri %19 performans göstermiştir. MAPE değeri %10 ile %20 arasında olduğu için iyi bir tahminleme yapmıştır.

FABRIC ORDER DEMAND FORECAST APPLICATION IN A TEXTILE COMPANY WITH THE ARTIFICIAL NEURAL NETWORK METHOD

SUMMARY

Keywords: Artificial Neural Network, Demand Forecast, Textile

In this study, it is aimed to estimate the fabric order amount of the next year by making a demand estimation study with the artificial neural network method based on the historical data of the fabric order amount of a textile company. Demand forecasting, which is of great importance for the company, provides an important input in strategic planning. Establishing the right strategic plans by predicting the future correctly enables companies to reach their goals. With the fabric order estimation, a supplier capacity plan can be made according to the amount of fabric to be used next year.

In fabric demand forecasting, demand forecasting was made with Matlab2018b software Neural Network Toolbox and Artificial Neural Network method, taking into account fabric type, fabric property, dye type, fiber mix, yarn number, special day information, consumer confidence index, economic confidence index and consumer price index. .

In the normalization of the data, the performance of the artificial neural network was compared by using the D-Min-Max and Min-Max normalization methods. With the Min-Max normalization method, it has been observed that the data is reduced between 0-1 and gives a more successful performance.

While creating the artificial neural network model, various experiments were made for the learning coefficient, momentum coefficient, and the number of neurons, and the ysa model, which gave 98.59% performance, was used in the estimation study. The artificial neural network model showed an MSE value of 0.001756 and a MAPE value of 19%. Since the MAPE value is between 10% and 20%, it made a good estimation.

BÖLÜM 1. GİRİŞ

Tahmin, bilinmeyen bir parametrenin değerinin, geçmişteki bilinen verilerle gelecekteki durumun öngörülmesidir. Talep tahmini tüketicilerin gelecek dönemlerde talep edecekleri mal ve hizmetin geçmişteki verilerle tahmin edilmesidir (Karaatlı ve ark.,2012).

Talep tahmini geçmiş dönemlerdeki verileri analiz ederek gelecek dönemin taleplerini önceden tahmin edilmesidir. Talep tahmini ile ilgili çalışmalar pek çok sektör için önem taşıyan çalışma alanıdır, fakat perakende sektörü farklı sektörlerle karşılaştırıldığında daha zorlu bir alandır. Bunun en önemli sebebi, talep tahminini etkileyecek değişkenlerin net bir şekilde bilinmemesidir. Hazır giyim sektörü de satışların birçok değişkenden etkilendiği, mevsimselliğin ve trendin yüksek olduğu bir alandır (Güven ve Şimşir, 2020).

Şirket yönetiminin stratejik kararlar vermesinde, kısa, orta ve uzun dönemli hedeflere ulaşmasında talep tahminin büyük etkisi bulunmaktadır (Ergün ve Şahin, 2017). Gelecekteki talebi doğru tahmin etmek doğru kapasite planlamasını da birlikte getirir. Doğru kapasite planlaması ile siparişler talep edilen terimde hazırlanabilir. Bu durum müşteri memnuniyetinin artmasına, stok maliyetinin azalmasına ve kaynakların doğru kullanılmasına olanak sağlayacaktır.

Bu çalışmada büyük bir tekstil firmasının tahmin edilecektir. Kumaş siparişi talep tahmininde ise kumaş kalitesi, rengi, miktarı, sipariş tarihi ve tedarikçi firması dikkate alınarak çalışma yapılacaktır. Yapılacak olan talep tahmini çalışması ile gelecekte hangi tedarikçi ne kadar miktarda sipariş verileceği tahmin edilerek önden planlama yapılabilecektir. Böylelikle aynı kumaş kalitesi ve sipariş zamanına sahip kumaşlar toplu olarak üretilip kumaş tedarik süresini kısaltacaktır. Bir modelin üretim gün

süresini etkiyelen en önemli faktör kumaş üretim gün süresidir. Kumaş üretim gün süresinde azalma sağlandığında modelin üretim gün süresi de ciddi anlamda azalacaktır. Kısa zamanlı üretim gün süresi malzemelerin depolardaki stok devir gün süresini düşürerek stok maliyetinde olumlu etki oluşturacaktır.

Gelecek dönemdeki kumaş sipariş miktarı önden tahmin edildiğinde kumaş tedarikçileri ile yüksek tonajlarda kumaş için toplu anlaşmalar yapılabilir, bu durum kumaş maliyetinin düşmesine olanak sağlar. Çünkü bir tedarikçi için en önemli bilgilerden birisi kendisine uzun vadede geçilecek sipariş miktarını bilmesidir.

Talep tahmini firmaların gelecek dönemlerde ihtiyaç duyacağı iş gücü, kapasite, ham madde, yardımcı malzeme, makine ve yapılması gereken yatırımın da tahmin edilmesini sağlar (Ergün & Şahin, 2017).

Gerçek talepten daha çok üretim yapıldığında stok maliyetlerinin artması, gelecek yıllara stok aktarımı ve modadan kopma gibi nedenlerle müşteri kaybı yaşanabilmektedir. Talepten az üretim olması durumunda ise satışlarda kayıp yaşanmakta ve müşterilerin ürün bulamaması sonucunda marka prestijinin olumsuz etkisi olmaktadır. Bu durum da müşteri bağlılığını ve müşterinin o markaya olan inancını olumsuz etkileyebilir (Güven ve Şimşir, 2020).

Artan talep değişkenliği durumları işletmelerin daha çok stok tutmasına sebep olur. Doğru talep tahmini, karar vermenin kalitesini belirlemede kritik öneme sahip bir faktördür. Hatalı sonuç veren tahminler, insan gücü, tedarik ve nakliye, envanter ve hizmet düzeyine gereksiz maliyetlere neden olabilir (Torkul ve ark., 2016).

Moda perakende sektöründe, tahmin doğruluğu seviyesi perakendecilerin kârında çok önemli bir rol oynamaktadır. Stoksuz kalmayı önlemek ve yüksek stok dolum oranını korumak için moda perakendecileri, spesifik ve doğru satış tahmin sistemlerine ihtiyaç duyar. Etkili bir tahmin sisteminin kilit faktörlerinden biri, uzun ve kapsamlı geçmiş verilerin mevcudiyetidir (Xia ve Wonk, 2014).

Moda endüstrisinde, talep tahmini özellikle karmaşıktır: şirketler, festivaller ve sosyo-ekonomik faktörleri ile birlikte mevsimsel satışlardan, promosyon etkinliklerinden, hava koşullarından, reklam ve pazarlama kampanyalarından derinden etkilenen çok çeşitli kısa yaşam döngüsü ürünleri ile çalışır (Fumi ve ark., 2013).



BÖLÜM 2. KAYNAK ARAŞTIRMASI

Literatürde Yer Alan Talep Tahmini Çalışmaları

Tekstilde tahmin yöntemini tasarlamak için her sınıfa ait öğelerin benzer satış grafiğine sahip olduğu optimal sınıfları bulmak amacıyla bulanık kümeleme yöntemi kullanılmıştır (Rabenasolo ve ark., 1997).

Kadın giyim ait satışları tahmin etmek için istatistiksel zaman serisi modellemesi ve YSA yöntemleri kullanılmıştır. YSA'nın istatistiksel zaman serisi modellemesinden daha iyi sonuç verdiği tespit edilmiştir (Frank ve ark., 2003).

Firmalar tekstil pazarına cevap vermek için satış tahmin sistemine güvenirler. Bununla birlikte, tekstil satışlarının özel kısıtlamaları (çok sayıda ve yeni ürün, kısa ömür) tahmin prosedürünü karmaşıktırmaktadır ve distribütörler, mevcut tahmin modelleri yerine satışların sezgisel tahmin yöntemlerini kullanmayı tercih etmektedir. Ürün satış tahminlerini otomatik olarak gerçekleştiren sinir ağlarına dayalı bir karar yardım sistemi kullanılış olup model performansları, önemli bir Fransız tekstil distribütöründen alınan gerçek veriler kullanılarak değerlendirilmiştir (Thomassey ve Happiette, 2007).

Tedarik zinciri talep tahmini için sinir ağları, tekrarlayan sinir ağları ve destek vektör makineleri ile birlikte gelişmiş makine öğrenimi tekniklerini uygulamış ve sonuçlarını geleneksel yöntemlerle karşılaştırmıştır. (Carbonneau ve ark., 2008).

Satış miktarı ve talebinde etkili olan bazı önemli faktörlerin (tasarım faktörleri gibi) birbirleriyle olan ilişkiyi araştırmak için aşırı öğrenme makinesi (ELM) adı verilen bir sinir ağı tekniği uygulanmıştır. Modelin performansları, Hong Kong'daki bir moda

perakendecisinden alınan gerçek veriler kullanılarak değerlendirilmiş olup deneysel sonuçlarda önerilen yöntem geri yayılım sinir ağlarına dayanan birkaç satış tahmin yönteminden daha iyi sonuç göstermektedir (Sun ve ark., 2008).

Hong Kong özel sektör konut talebini doğrudan tahmin etmek için dört öncü gösterge modeli geliştirilmiş ve karşılaştırılmıştır. Kullanılan modeller Lineer Regresyon Analizi (LRA), Genetik Algoritmalar (GA) GA-LRA modeli, burada LRA'nın gösterge değişkenlerini seçmek için kullanıldığı ve yerel optimum olasılığını düşürmek için Uyarlamalı Mutasyon Hızı (AMR) ile GA-LRA modeli. Bulgular, AMR'li GA-LRA modelinin daha uzun bir süre boyunca en doğru tahminleri sağladığını göstermektedir (Thomas ve ark., 2008).

Tahmin sistemi için ideal ağ yapısının aranmasında evrimsel bir hesaplama yaklaşımı önerilmiştir. Analizde iki yıllık hazır giyim satış verileri kullanılmıştır. Hazır giyim satışlarının tahmini için optimize edilmiş sinir ağları yapısı geliştirilmiştir. Modellerin performansları, geleneksel tahmin modelleri ve temel tam bağlantılı sinir ağları ile karşılaştırılmıştır. Önerilen algoritmaların moda perakendeciliği tahmini için yararlı olduğunu, düşük talep belirsizliği ve zayıf mevsimsel trend özelliklerine sahip ürünler için performansı geleneksel SARIMA modelinden daha iyi gözlemlenmiştir (Au ve ark., 2008).

Giyim sektöründeki satış tahminleri gerçekleştiren farklı tahmin modelleri kullanılmıştır. Bu modeller, sinir ağları, bulanık mantık, ve veri madenciliği gibi gelişmiş yöntemlere dayanmaktadır. Bu yöntemlerin tedarik zincirine yönelik faydalarını değerlendirmek için, kaynak bulma ve tahmin süreçlerinin gerçek verilerine dayalı bir simülasyon gerçekleştirilmiş ve analiz edilmiştir (Thomassey, 2010).

Hem (ELM) hem de yanı sıra geleneksel istatistiksel yöntemleri kullanan yeni bir model önerilmiştir. Gerçek veri setleri ile deneyler yapıp diğer geleneksel yöntemlerle bir karşılaştırma yapılmıştır. ELM hızlı tahmin (ELM-FF) modelinin hızlı ve etkili olduğunu tespit etmiştir. (Yu ve ark., 2011).

Satış tahmini doğruluğunu iyileştirmek için değiştirilebilir öğelerle döngü kesme birikimine dayalı yeni bir mevsimsel ayırık gri tahmin modeli sunulmuştur. Önerilen tahmin modeli, iki önemli sorun olan mevsimsellik ve sınırlı verinin üstesinden gelmek için oluşturulmuştur. Önerilen algoritmalar, yüksek kaliteli, orta ve temel moda ürünleri satan üç moda perakendecisinin gerçek POS verileri kullanılarak doğrulanmıştır. Önerilen modelin, kısa tarihsel verilerle moda perakende satış tahminleri için pratik olduğu ve diğer son teknoloji tahmin tekniklerinden daha iyi performans gösterdiği bulunmuştur (Xia ve Wonk, 2014).

Sunucu sistemlerinin taleplerini tahmin etmek amacıyla yapay sinir ağı yaklaşımı kullanılmıştır. Geçmiş talep verilerindeki eğilimler ve mevsimsellik kalıpları çıkarılıp modellenmiştir. Ardından, ağ için uygun parametreleri oluşturmak için bir deney tasarımı kullanılmıştır (Saha ve ark., 2014).

Destek vektör regresyonuna dayalı kümeleme tabanlı bir satış tahmin şeması önerilmiştir. Önerilen şema ilk önce tüm eğitim satış verilerini birkaç ayırık kümeye bölmek için k-means algoritmasını kullanılmıştır. Daha sonra, her gruba tahmin modeli oluşturmak için SVR uygulanmıştır. Son olarak, belirli bir test verisi için, test verilerinin ait olduğu kümeyi bulmak için üç benzerlik ölçümü kullanılır ve ardından tahmin sonucu oluşturmak için karşılık gelen eğitilmiş SVR modelini çalıştırılmıştır (Dai ve ark., 2015).

Daha önce aralıklı talebi tahmin etmek için aşırı öğrenme makinesi adı verilen daha hızlı ve daha basit bir öğrenme algoritması denenmemiştir. Çalışmada geri yayılım ve aşırı öğrenme makineleri tarafından eğitilen sinir ağları, farklı girdi kalıpları ve mimarileri birleştirerek gerçek zamanlı serilerde aralıklı talep için standart tahmin yöntemlerinin yanı sıra karşılaştırmalı sinir ağları ile karşılaştırılmıştır (Lolli, ve diğerleri, 2017).

Perakende giyim sektöründeki mağaza zincirinin bir mağazasına ait, mevsimsel talep karakteristiğine sahip ürün ile talebi mevsimsel olmayan başka ürün için geçmiş veriler toplanmıştır. Hava sıcaklığı, indirim ve mağazaya gelen müşteri sayısı faktörlerinin

ürünlerin talebine etki ettiği düşünülerek iki başka Yapay Sinir Ağı Modeli (ANN) kurulmuştur. Mevsimselliği dikkate alan Zaman Serisi ANN modelinin, klasik ANN modeline kıyasla mevsimsel talep yapısına sahip ürünün talebini daha doğru tahmin ettiği görülmüştür (Satoğlu ve Eren,2017).

Kullanıcı tarafından oluşturulan Facebook verilerinin nicelik ve kalitesinin ürün tahminlerini geliştirmek için nasıl kullanılabileceğini göstermiştir. Çalışmada örnek dışı tahmin hatalarını azaltmak için kullanıcı tarafından oluşturulan başka bir içerik türünün (özellikle Google Trendler'den elde edilen müşteri arama verilerinin) nasıl kullanılabileceğini gösterilmektedir. Çevrimiçi bir perakendeciyle ile yapılan çalışma sonucu, zaman serisi modellerine müşteri arama verilerinin eklenmesinin örneklem dışı tahmin hatalarını iyileştirdiğini gösterdi (Boone ve ark., 2018).

Müşteriden gelen siparişlerin periyodik olarak ancak sürekli olmayan bir şekilde üretildiği talep tahminine odaklanmıştır. Regresyon modellerinin uygulanması, bir siparişin tahmin edildiği zamansal anları belirlemek için bir ilk sınıflandırmanın düşünüldüğü ve daha sonra bu tür bir siparişin tahmin edilen miktarını elde etmek için bir regresyon üretildiği hibrit yöntemlerle karşılaştırılmıştır. Basit regresyon modelleriyle karşılaştırmanın yanı sıra her iki aşama için uygun yöntemlerin seçilmesi için gerçek talep verilerine bir uygulama ile tamamlanmaktadır (Álvarez-López ve ark., 2019).

Makine öğrenimi kullanılarak restoran talep tahmini çalışması yapılmıştır. Çalışmada ay, gün, hava durumu, olaylar gibi çeşitli faktörleri göz önünde bulundurarak bir talep tahmin modeli kurmak kurulmuştur. Makine öğrenimi talep tahmin sonucu ile gerçek mağaza verilerini karşılaştırılmıştır (Tanizaki ve ark., 2019).

Perakende hazır giyim sektöründe ürün çeşitliliği dikkate alınmış ve hata oranını en aza indirmek için yapay zeka kullanılarak satış tahmini yapılmıştır. Bu kapsamda destek vektör makineleri (SVM) ve yapay sinir ağları (YSA) gibi yapay zeka modelleri kurulmuş ve veri setlerinden çıkarımlar yapılmıştır. YSA'nın SVM'den daha iyi sonuç verdiği görülmüştür (Güven ve Şimşir, 2020).

Perakende giyim talebini tahmin etmek için en bilinen makine öğrenme metodlarından ikisi olan random forest (RF) ve k-nearest neighbour (KNN) metodu kullanılmıştır. Çalışma sonucunda RF, KNN'ye kıyasla dört veri setinin hepsinde daha iyi performans göstermiştir (Güven ve ark., 2021).

Amerika Birleşik Devletleri merkezli bir B2B sunucu şirketinde önce satış verilerine dayalı zaman serileri ve makine öğrenimi modelleri çalışıldı. Ardından en uygun modeli temel alınarak sunucu endüstrisi için harici bilgi endeksleri olarak ilgili pazar sinyallerini toplamak için bir web tarayıcısı ve Google Trendler'i kullanıldı. Talep dalgalanmaları hesaba katılacak şekilde tahmin sonuçlarını ayarlamak için seçilen temel modele dahil edildi. Temel modele harici bilgiler dahil edildiğinde daha iyi performans göstermektedir (Tsao ve ark., 2021).

BÖLÜM 3. MATERYAL VE YÖNTEM

Materyal

Araştırmada, bir tekstil firmasına ait 4 yıllık kumaş sipariş verileri kullanılmıştır. Kumaş talep tahmininde kumaş türü, kumaş özelliği, boya cinsi, elyaf karışı, iplik numarası, özel gün bilgisi, tüketici güven endeksi, ekonomik güven endeksi ve tüketici fiyat endeksi dikkate alınarak Matlab2018b yazılımı Neural Network Toolbox'ı ile Yapay Sinir Ağı metoduyla talep tahmini yapılmıştır.

Yapay Sinir Ağları

Yapay sinir ağları, gerçekleşmiş verileri kullanarak durumları öğrenebilen, etrafından gelen durumlara karşılık olarak nasıl bir tepki üreteceğini belirleyen bilgisayar sistemidir. Örneklerden elde ettiği bilgiler ile kendi deneyimini oluşturur ve daha sonra benzer konularda benzer kararlar verir. (Öztemel ,2003)

Yapay sinir ağlarının öğrenme özelliği, araştırma çalışması yapan kişilerin dikkatini çeken en önemli unsurlarından biridir. Dolayısıyla bir durum ile ilgili girdi ve çıktılar arasındaki ilişkiyi, halihazırdaki mevcut örneklerden öğrenerek geçmişte hiç görülmemiş durumları, önceki örneklerden ilişkilendirerek ilgili duruma çözümler üretebilme özelliği yapay sinir ağlarındaki zeki davranışın da temelini teşkil eder. (Yazıcı, 2010)

YSA'nın genel özellikleri ağ modeline göre değişkenlik göstermektedir. YSA'nın genel özelliklerinden bazıları aşağıdaki gibidir; (Öztemel ,2003)

- a. Yapay sinir ağları örnekleri kullanarak öğrenirler

- b. Görülmemiş veriler hakkında bilgi üretebilirler
- c. Şekil ilişkilendirme ve sınıflandırma yapabilirler
- d. Yapay sinir ağları makine öğrenmeleri gerçekleştirebilirler
- e. YSA'nın çalıştırılması için önce eğitilip sonra performansları test edilir.
- f. Eksik bilgi ile çalışabilirler.
- g. Yalnız nümerik bilgiler ile çalışabilmektedir.

Yapay sinir ağları pekçok alanda ve sektörde kullanılabilmektedir. Bu çalışmada tekstil sektöründe kullanılmış olmasına rağmen, sağlık, bankacılık, turizm, otomotiv, eğitim gibi farklı sektörlerde kullanım alanına sahiptir.

Yapay sinir ağlarının avantajları aşağıdaki gibidir(Katırcıoğlu, 2019);


- a. Eksik veri olsa bile öğrenme yetekleri sayesinde sonuç verebilmektedir.
- b. Benzer olayları yorumlayabilmektedir.
- c. Çok sayıda kısıt ve parametre ile çalışabilmektedir. Bu sebepten büyük boyutlu problemlerde kullanılabilir.
- d. Birden çok işi aynı esnada yapabilmektedir.

Yapay sinir ağlarının önemli dezavantajları ise aşağıdaki gibidir; (Öztemel, 2013)

- a. YSA'nın donanım bağlı çalışmaları önemli bir problemdir.
- b. Probleme uygun olan ağ yapısını belirleyebilmek için deneme yanılma yapılır.
- c. Parametre değerlerinin belirlenmesinde bir kuralın olmaması önemli başka bir problemdir.
- d. Sadece nümerik verilerle çalışmaktadır.
- e. Ağ eğitiminin ne zaman biteceğini belirlemek için oluşturulmuş kural seti yoktur.
- f. Ağın davranışlarının açıklanamamasıdır.

3.1.1. Biyolojik sinir hücresi

İnsan beynindeki sinir hücreleri(nöronlar) 4 bölümden meydana gelmektedir. Bunlar: hücre gövdesi, dentrit, akson ve sinaps. Dentrit, hücre gövdesi, akson ve sinaps. Biyolojik sinir hücresinin yapısı Şekil 3.1.'de belirtilmiştir.



Şekil 3.1. Biyolojik Sinir Hücresi (www.wowslides.com., 2022)


Duyu organlarından nöronlar ile beyine bilgi iletilir. Beyinde oluşan cevap da nöronlar yardımıyla organlara taşınmaktadır. Dentrit uçlarından diğer hücrelerden gelen bilgiler alınır, hücre gövdesine iletilir. Hücre gövdesinde değerlendirilir ve aksona iletilir. Akson ucu ile diğer hücrenin dentriti arasındaki bağlantıya ise sinaps denir.

3.1.2. Yapay sinir hücresi

Yapay sinir ağları insanlara ait sinir hücrelerinin taklitini yaparak oluşturulmuştur. 5 temel elemanı Şekil 3.2.'de belirtilmiştir.

- a. Girdiler: Sinir hücresine iletilen bilgilerdir.

- b. Ağırlıklar: İletilen bilginin önemini ve etkisini gösterir.
- c. Toplama fonksiyonu: Hücreye iletilen net girdi değerinin ağırlık ile çarpılarak toplanılmasıdır.
- d. Aktivasyon fonksiyonu: İletilen girdiye istinaden üreteceği çıktıyı belirler.
- e. Hücrenin çıkışı: Aktivasyon fonksiyonu tarafından oluşturulan çıktıdır.



Şekil 3.2. Yapay Sinir Ağı Yapısı (www.pythondunyasi.com., .2022)

Biyolojik sinir ağı ile yapay sinir ağının karşılaştırması Tablo 3.1.'de verilmiştir.

Tablo 3.1. Biyolojik Sinir Hücresi ile Yapay Sinir Ağının Karşılaştırılması(Öztürk ve Şahin, 2018)


Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

3.1.3. Yapay sinir ağı yapısı

Yapay sinir hücrelerinin bir araya gelmesiyle yapay sinir ağı oluşur. Genel olarak 3 katman halinde ve her katmanın içinde paralel olarak bir araya gelen ağlardan oluşur. Bu katmanlar aşağıdaki gibidir (Öztemel, 2003);

- Girdi Katmanı:** Girdi katmanındaki elemanlar çevreden bilgileri alarak ara katmanları iletmekle sorumludur. Bazı yapay sinir ağlarının girdi katmanında herhangi bir bilgi işleme olmaz.
- Ara Katmanlar:** Girdi katmanından iletilen bilgiler işleme alınarak çıktı katmanına iletilir. Bu bilginin işlenmesi ara katmanlarda gerçekleştirilir. Bir yapay sinir ağı için birden çok ara katman olabilir.
- Çıktı Katmanı:** Çıktı katmanındaki elemanlar ara katmandan iletilen bilgiler işleyerek ağı girdi katmanına sunulan girdi seti(örnek) için oluşması gereken çıktıyı üretirler. İletilen çıktı böylelikle dış dünyaya gönderilir.

Yapay sinir ağı yapısı ve katmanları Şekil 3.3.'de belirtilmiştir.



Şekil 3.3. Yapay Sinir Ağı Yapısı(Yavuz ve Deveci, 2013)

3.1.4. Yapay sinir ağı sınıflandırılması

3.1.4.1. Katmanlarına göre yapay sinir ağları

Tek katmanlı yapay sinir ağları girdi ve çıktı katmanından oluşmaktadır. Ağıın çıktısı ağırlıklandırılmış girdi değerin eşik değeri ile toplanmasıyla sonuç elde edilir. (Öztemel, 2003).

Çok Katmanlı Yapay Sinir Ağı modeli, bir giriş katmanı ,bir veya daha çok gizli katmanı ve çıktı katmanından meydana gelmektedir. Her katmanda bir veya daha çok işlem elemanı yer almaktadır. Bir katmandaki tüm işlem elemanları bir üst katmandaki tüm işlem elemanlarına ilişkilidir.(Ataseven, 2013).

3.1.4.2. Yapılarına göre yapay sinir ağları

İleri beslemeli yapay sinir ağlarında bilginin iletilmesi tek yönde olmaktadır. Yani bilgi giriş katmanından çıkış katmanına doğru ilerler (Katırcıoğlu, 2019).

Geri beslemeli yapay sinir ağlarının dinamik hafızaları bulunmaktadır. Bir esnadaki çıkış, hem o esnanın hem de önceki girişleri yansıtır. Bu sebepten, özellikle tahmin uygulamalarında başvurulur. Bu ağlar çeşitli problemlerin tahmininde başarılı sonuçlar vermiştir. (Yazıcı, 2010).

3.1.4.3. Öğrenme yöntemlerine göre yapay sinir ağları

Yapay sinir ağlarının öğrenmesinde iki öğrenme yöntemi mevcuttur. Bunlar yöntemler danışmanlı ve danışmansız öğrenmedir. Yapay sinir ağlarında en çok tercih edilen öğrenme yöntemi danışmanlı öğrenmedir. Yapay sinir ağına örnek olarak bir çıktı verilerek ağıın ürettiği çıktı kıyaslanır. İki çıktı arasındaki fark hata olarak alınır (Ataseven, 2013).

Yapay sinir ağıları devamlı araştırılan ve büyüyen bir öğrenme metodudur. (Ataseven, 2013) Danışmansız öğrenme yönteminde ağı doğru çıktılar verilmez, sadece girdi veri seti verilir. (Katırcıoğlu, 2019).



BÖLÜM 4. ARAŞTIRMA BULGULARI

Talep tahmini uygulaması, kumaş sipariş verilerinden yola çıkılarak yapay sinir ağı yöntemi ile MATLAB(2018B Sürümü) yazılımı ile gerçekleştirilmiştir.

Tedarik zinciri yönetimi yapan tekstil firmasına ait Erkek Yetişkin grubuna ait 4 yıllık kumaş sipariş verileri baz alınarak talep tahmini çalışması yapılmıştır. Tahminleme verileri dikkate alınarak kumaş tedarikçileri ile önden kumaş anlaşmaları, kapasite planlamaları yapılabilecektir. Kumaş sipariş miktarını etkileyen faktörler için uzman görüşü alınmıştır.

Bu bölümde ele alınan problemin yapay sinir ağı metoduyla uygulama aşamaları anlatılmış ve kumaş sipariş miktarını etkileyen faktörler incelenmiştir.

Tekstil Sektöründe Tedarik Zinciri Yönetimi

Tedarik zinciri yönetimi; üreticiler, tedarikçiler, dağıtımıcılar ve müşterilerden oluşan malzeme, bilgi ve parasal akışların yönetimini içermektedir. Bu akış kendi içerisinde ya da farklı işletmeler arasındaki koordinasyon tedarik zinciri yönetiminin başarısını sağlayacaktır. (Sakallı, 2007)

Tekstil sektöründe artan rekabetle birlikte karlılığın sınırlarını bayağı aşağılara indirmekte, karlı kalmak ve karlılığını yukarılara çekmeyi amaçlayan işletmeler, üretim süreçlerini optimum seviyede akıcı ve kısa süreli duruma dönüştürmek durumundadırlar. Eldeki kaynakları en verimli şekilde kullanmak, tedarik ve stoğa ait süreçleri olabildiğince aktifleştirmek, maliyetleri minimum kılmak kısacası daha kaliteli ürünü daha kısa zamanda ve daha az bir maliyetle üretmek önem taşımaktadır. (Kaya ve Öztürk, 2018)

Tekstil sektöründe doğrudan üretim yapan ve pazarlayan işletmelerin yanı sıra, aracı iş yerleri ile anlaşarak çalışan işletmelerde mevcuttur. Üretici ile alıcı arasındaki iletişimi sağlamakla ve işin tüm süreçlerinden aracı kurum sorumludur. Tekstil ve hazır giyim sektöründeki üreticiler, genellikle ürünlerinin tamamını tek başına kendileri üretmemektedir. Üretimin her bir adımı değişik işletmelerde yapıldığını düşünüldüğünde bu ürünlerin zamanında ve doğru üretilmesi için bu işletmelerin iletişim halinde olması ve birlikte çalışması gerekmektedir. İşlemlerden birinde aksaklık olması veya bir üretim hatasının olması diğer bütün işlemleri olumsuz etkileyebilecektir. (Karabay, 2016)

Tedarik ve talebi dengede tutabilmek doğru tahminleme çalışmalarının yapılmasıyla başlar (Krajewski ve ark., 2014) Tekstil sektöründe tedarik zinciri iplikten başlar ve mağazada son bulan süreçlerden oluşmaktadır. Bu süreçte çalışılan birden fazla tedarikçi mevcuttur.

Uygulamanın yapıldığı tekstil sektörü tedarik yönetiminden oluşmaktadır. Ana müşteriden sipariş belgesinin gelmesiyle başlayıp, hazır ürünlerin müşterinin deposuna sevk edilmesi ile ürün hayat döngüsü son bulur.


Şekil 4.1.'de belirtildiği gibi müşteriden sipariş belgelerinin iletilmesi ile süreç başlamaktadır. Sipariş belgelerinde yer alan bilgiler doğrultusunda ihtiyaç duyulan kumaş ve aksesuar hesaplaması yapılır, ürün ağacı ve iş planı oluşturulur.

Ürün ağacı oluşturulduktan sonra ihtiyaç duyulan aksesuar için aksesuar tedarikçisinden, kumaş için kumaş tedarikçisinden teklif alınır ve istenen şartlara en uygun tedarikçiye sipariş geçilir.

Kumaş ve aksesuar tedarikçisi tarafından sipariş edilen hammaddeler hazırlanarak depoya sevkiyatı gerçekleşir. Gelen malzemeler depo kabulü esnasında kontrol gerçekleştirilir.

Depoya sevk edilen kumaşlar kesilmesi için kesimhaneye yönlendirilir. Kesimhanede yapılan pastal hesaplamaları doğrultusunda kumaş kesimi gerçekleştirilir. Kesilen kumaşlara eğer baskı/nakış yapılacak ise baskı/nakış atölyelerine sevk edilir. Talep edilen model doğrultusunda baskı/nakış işlemi gerçekleştirilir. Baskı/Nakış işlemi yoksa kesilen kumaşlar dikim işlemi için fason atölyeye yönlendirilir.

Kesilmiş kumaş yarımamülü ve aksesuarlar fason atölyeye gönderilir. Fason atölyede dikim ve ütü-paket işlemi tamamlanır. Paketlenen bitmiş ürünler müşterinin deposuna sevk edilir.




Şekil 4.1. Tekstil Sektöründe Ürün Hayat Döngüsü

Kumaş Üretimi ve Tedarik Yönetimi

Kumaşın ana maddesi ipliktir. Bu sebepten kumaş üretiminin ilk safhası iplik üretimidir. Kumaş üretim safhaları Şekil 4.2.'de belirtilmiştir.

İpliklerin biraya getirilmesiyle kumaş oluşturulur. İki iplik sisteminin dik bir açıyla belli nizamla göre ilişki kurmasıyla oluşan kumaşlara dokuma kumaş denir. Yuvarlak örme makinelerinde iğneler dairesel yatak üzerine dizilir. Öteki örücü elemanların iğnelere özgü dairesel bir şekilde konumlandırıldığı örme makinelerinde oluşturulan kumaşlara örme kumaş denir (www.tekstilsayfasi.blogspot.com., 2022).



Şekil 4.2. Kumaş Üretim Safhaları

Ön Fikse işleminin amacı iplik ve kumaşın yapısal eşitliğini sağlamak ve iç gerilimleri azaltmaktır. Böylelikle çekmezlik değerleri iner, yüzey kırışıklıkları ve kenar dönmeleri azalır.

Renklendirme operasyonu, boyar maddelerin kumaş ile işlem görmesidir. Bu işlemle kumaş sadece renk değiştirmekle kalmayıp aynı esnada bu renk kumaş üzerinde kalıcı olur.

Sanfor operasyonun amacı, kumaşın en-boy standartlığını sağlamak, tuşe vermek ve buruşuklukları gidererek ütülerdir.

Kumaş son kontrol operasyonunda bitmiş kumaşların son kontrolü yapılarak kesilmek ve dikilmek üzere kumaşlar sevk edilir.

Yukarıda kumaş üretim safhalarından bahsedilmiştir. Bu safhalardan da anlaşıldığı üzere kumaş üretimi belirli aşamalarından geçen ve uzun süren bir prosese sahiptir. Bu sebepten kumaş tedarik yönetimi çok önem taşımaktadır.

Model üretimi için ihtiyaç duyulan kumaş miktarı hesaplandıktan sonra kumaş tedarikçilerine sipariş geçilir. Kumaş tedarikçisi tarafından siparişte talep edilen bilgiler doğrultusunda istenen kalite ve zamanda üretilmesi talep edilir.

Kumaş üretiminin her safhası takip edilir ve kontrol edilir. Kumaş üretim safhasında numune kumaş örnekleri iletilir ve kontrol edilir. Talep edilen kumaşın üretimi tamamlandığında kumaş depoya sevkiyatı gerçekleşir.

Tedarik Zinciri Yönetiminde Kumaş Talep Tahmininin Önemi

Tekstil sektöründe talep tahminini etkileyen birçok unsur bulunmaktadır. Tahminleme doğru yapılmadığında tedarik süreci olumsuz etkilenir. Bir modelin üretim gün süresini en çok kumaş tedarik süresi etkilemektedir. Kumaş Tedarik süresinde yapılacak olan iyileştirmeler modelin toplam üretim süresini ciddi anlamda azaltacaktır. Kumaş üretim gün süresindeki azalma da zamanında üretim performansını arttıracaktır.

Yapılan doğru tahminleme çalışmaları ile tedarikçilere geçilecek olan siparişler önceden tanımlanabilir ve hazırlık süreci başlar. Eğer mevcut tedarikçi kapasitesi yeterli değil ise yeni tedarikçi arayışına girilir ya da tedarikçinin kapasitesini büyütmesi talep edilebilir. Tedarikçi de bu öngörü sayesinde kapasite planlamasını önceden yapabilecektir. Tedarikçinin bu ön hazırlığı hem üretim gün süresine hem kaliteye olumlu olarak yansıyacaktır.

Modellerin üretiminde kullanılacak kumaşlar zamanında üretilip tedarik edilemezse siparişler planlanan termin tarihine yetişmez. Bu durum ise müşteri memnuniyetsizliği ve sipariş kayıplarına sebep olabilmektedir. Tedarik zincirinde bir adımda gerçekleşen geçikme diğer adımları da olumsuz etkiler.

Perakende sektörü genellikle hızlı satış eğilimindedir. Eğer bir müşteri talep ettiği bir modeli talep ettiği özelliklerde bulamaz ise rakip mağazaya yönelip ihtiyacını gidermektedir. Bu durum da mağazalar için satış kaybına sebep olmaktadır. Bu sebepten müşterinin ihtiyacını doğru tahmin etmek oldukça önemlidir.(Güven, 2020).

Kumaş sipariş miktarının önceden tahminleme yapılarak öngörülmesiyle kumaş tedarikçilerine toplu kumaş anlaşmaları yapılabilir, böylelikle kumaş fiyatlarında da indirim gerçekleşebilir. Bir ürünün maliyetini en çok kumaş maliyeti oluşturur. Kumaş maliyetinde yapılacak olan bir iyileşme ürün maliyetine de yansıyacaktır.

Problemin Tanımlanması

Bu çalışma ile kumaş sipariş miktarının aylık olarak tahmin edilmesi ve tahmini etkileyen faktörlerin belirlenmesini amaçlanmaktadır. Kumaş sipariş miktarını etkileyen, yapay sinir ağı modelinde ele alınan girdiler aşağıdaki gibidir. Bu çalışmada kullanılan verilen çalışmanın yapıldığı şirkete ait satın alma raporlarından çekilmiştir.

- a. Kumaş Türü: Tekstilde çok farklı çeşitlerde kumaş kullanılmaktadır. Yaptığımız çalışmada da erkek departmanında kullanılan kumaş türleri ve kodlarının veri seti Tablo 4.1.'deki gibidir.

Tablo 4.1. Kumaş Türü ve Kodu

Kumaş Türü	Kumaş Türü Kodu
ÇİFT TOP PİKE	1
İKİ İPLİK	2
İTERLOK	3
KAPPA	5
KAŞKORSE	6
POLAR	7
RAŞEL	8
RİBANA	9
SELANİK	10
SÜPREM	11
TEK TOP PİKE	12
ÜÇ İPLİK	13
WAFFLE	14

- b. Kumaş Özelliği: Kumaş üzerinde yapılan işlemi ifade etmektedir. Yaptığımız çalışmada da erkek departmanında kullanılan kumaşın özellikleri ve kodları veri seti Tablo 4.2.'deki gibidir.

Tablo 4.2. Kumaş Özelliği ve Kodu

Kumaş Özelliği	Kumaş Özelliği Kodu
DÜZ	1
İPLİĞİ BOYALI	2
METRAJ BASKI	3
JAKARLI	4
DOUBLE FACE	5
DİAGONAL	6
ELYAF BOYA	7

- c. Boya Cinsi: Kumaşlara uygulan boyama proses cinsidir. Yaptığımız çalışmada da erkek departmanında kullanılan kumaşların boya cinsi ve kodlarının veri seti Tablo 4.3.'deki gibidir.

Tablo 4.3. Boya Cinsi ve Kodu

Boya Cinsi	Kod
REAKTİF	1
PİGMENT	2
DİSPERS	3

Tablo 4.3. (Devamı)

Boya Cinsi	Kod
REAKTİF + DİSPERS	4
YIKAMA	5
O.BEYAZ	6

- d. Elyaf Karışımı: İçeriğinde özellikle elyaf ve filamentler bakımından birbirine farklı bileşenler bulunan ipliklerle karışımıdır. (www.tekstilsayfasi.blogspot.com., 2022.). Veri setindeki elyaf karışımları Tablo 4.4.'de belirtilmiştir.

Tablo 4.4. Elyaf Karışımı ve Kodu

Elyaf Karışımı	Elyaf Karışımı Kodu
%100 PAM	1
%65 PAM %35 PES	2
%50 PAM %50 PES	3
%39 PES %21 VIS %40 AKR	4
%95 PAM %5 LYC	5
%96 PAM %4 LYC	6
%97 PAM %3 LYC	7
%100 PES	8
%51 PAM %49 PES	9
%40 PES %37 AKR %19 VIS	10
%70 PAM %30 PES	11
%66 PAM %34 PES	12
%55 PES %45 PAM	13
%55 PAM %45 AKR	14
%65 PAM %32 PES %3 LYC	15
%65 PES %35 VIS	16
%65 PAM %33 PES %2 LYC	17
%60 PAM %40 PES	18
%80 PAM %20 PES	19
%95 PAM %5 PES	20
%93 PAM %7 LYC	21
%92 PAM %8 PES	22
%45 AKR %40 PES %10 PAM %5 VIS	23
%55 PAM %40 PES %5 LYC	24
%70 PES %30 PAM	25
%67 PES %33 VIS	26
%96 PAM %4 LYC	27

Tablo 4.4. (Devamı)

Elyaf Karışımı	Elyaf Karışımı Kodu
%90 PAM %10 PES	29
%98 PAM %2 PES	30
%95 PES %5 LYC	31
%64 PAM %31 PES %5 LYC	32
%97 PES %3 LYC	33
%60 PES %40 VIS	34
%55 PAM %45 PES	35
%100 VIS	36
%40 PES %35 PAM %24 AKR	37
%60 PES %40 PAM	38
%100 KTN	39
%50 PAM %45 PES %5 LYC	40
%58 PAM %42 PES	41
%72 PAM %28 PES	42
%97 PAM %3 NYL	43
%98 PAM %2 LYC	44
%85 PAM %15 PES	45
%63 VIS %32 PES %5 LYC	46
%76 PAM %24 PES	47
%97 PAM %3 PES	48
%67 PAM %30 PES %3 LYC	49
%49 PES %47 PAM %4 LYC	50
%63 PAM %34 PES %3 LYC	51
%99 PAM %1 LYC	52
%48 PAM %48 PES %4 LYC	53
%63 PAM %32 PES %5 LYC	54
%64 PAM %36 PES	55
%54 PAM %46 PES	57
%69 PAM %31 PES	58
%98 PAM %2 AKR	59
%93 PAM %7 PES	60
%63 PES %37 PAM	61

- e. İplik Numarası: Numarası: İplik uzunluğu ve ağırlığı arasındaki ilişkiyi ifade eden, ipliğin incelik derecesini gösteren değerdir. Yaptığımız çalışmada da erkek departmanında kullanılan kumaşların iplik numarası ve normalizasyonda kullanılan kodlarının veri seti Tablo 4.5.'deki gibidir.

Tablo 4.5. İplik Numarası ve Kodu

İplik Numarası	İplik Numarası Kodu
110	1
160	2
170	3
190	4
200	5
210	6
220	7
230	8
260	9
280	10
290	11
310	12
320	13
330	14
340	15
410	16
450	17
470	18
480	19
490	20
500	21
520	22
530	23
535	24
540	25
555	26
560	27
570	28
580	29
590	30
600	31
610	32
620	33
630	34
640	35
680	36
730	37
750	38
780	39
790	40
805	41
840	42

- f. Tüketici Fiyat Endeksi (TÜFE) : Tüketici Fiyat Endeksi (TÜFE) : Tüketici tarafından satın alınan mal ve hizmetlerin fiyatlarında meydana gelen değişimi hesaplayan endekstir. Yılın her ayının belirli günlerinde mal ve hizmet fiyatlarındaki değişim, bu ağırlıklara ölçülerek o ayın tüketici enflasyon rakamına ulaşılmaktadır. (Sarı, 2016)
- g. Ekonomik Güven Endeksi: Üretici ve tüketicilerin genel ekonomik duruma ait değerlendirme, beklenti ve eğilimlerini özetleyen bir bileşik endekstir. (www.data.tuik.gov.tr., 2022)
- h. Tüketici Güven Endeksi: Aylık tüketici eğilim anketi ile tüketicilerin maddi durum ve genel ekonomisine dair mevcut durum değerlendirmesi yapılarak gelecek dönemdeki beklentileri, harcama ve tasarruf eğilimleri ölçülmektedir. (www.data.tuik.gov.tr., 2022).

Verilerin Normalizasyonu

Yapay sinir ağı yönteminde girdi ve çıktı verilerine normalizasyon yapılarak verilerin eğitimi daha verimli hale getirilebilir. Ağın eğitimi veri setini normalize etmeden çok uzun sürebilir (Yavuz ve Deveci, 2018). Çalışmada veri setinde yer alan sözel veriler numerik verileri dönüştürülmüştür.

Normalizasyonda farklı teknikler kullanılmaktadır. Bu çalışmada Min-Max Normalizasyonu ve D-Min-Max Normalizasyon yöntemi kullanılmıştır. Veri setinde yer alan verilerin öncelikle Tablo 4.6.'da gösterildiği gibi min ve max değerleri bulunmuştur.

Tablo 4.6. Veri Seti Max-Min Değerleri

	Kumaş Kalite	Kumaş Özelliği	Boya Cinsi	Elyaf Karışımı	İplik Numarası	Ekonomik güven endeksi	Tüketici güven endeksi	TÜFE
min	1	1	1	1	1	97,26	82,23	140,6
max	14	7	6	60	42	105,86	97,43	203,07
max-min	13	6	5	59	41	8,60	15,20	62,47

Min Max Normalizasyon yöntemi verileri doğrusal olarak normalize eder. Min-Max normalizasyonunda en küçük veri 0 değerini alır. En büyük veri ise 1 değerini alır. Böylelikle veriler Min Max Normalizasyon yöntemi ile Denklem 4.1'de eşitlik kullanılarak 0-1 arasına indirgenir.

$$x' = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (4.1)$$

Bu formülde x' normalize edilmiş veriyi, x_i girdi değerini, $x_{\min}$ girdi verilerindeki en küçük değeri, $x_{\max}$ girdi verilerindeki en büyük değeri ifade etmektedir. Min Max Normalizasyon yöntemi ile normalize edilmiş örnek veriler Tablo 4.7.'de gösterilmiştir.

Tablo 4.7. Min Max Normalizasyon Yöntemiyle Normalize Edilmiş Örnek Veri

Kumaş Türü	Kumaş Özellik	Boya Cinsi	Elyaf Karışım	İplik	Ekonomik güven endeksi	Tüketici Güven endeksi	TÜFE	Kumaş Sipariş Miktarı
0,7692	0,0000	0,0000	0,2203	0,0244	0,6276	0,6298	0,1229	0,0000
0,0000	0,0000	0,0000	0,0000	0,0244	0,7348	0,4537	0,1658	0,0317
0,1538	0,5000	0,6000	0,1356	0,1463	0,2950	0,3382	0,9083	0,9714
0,3846	0,1667	0,6000	0,0508	0,0732	0,5197	0,5164	0,4117	0,4112
0,9231	0,0000	0,6000	0,1695	0,5366	0,0000	0,0000	0,3850	0,1490
0,6154	0,0000	0,0000	0,0000	0,1463	0,0000	0,0000	0,3850	0,1490
0,1538	0,5000	0,6000	0,1356	0,1463	0,0000	0,0000	0,3850	0,1581
0,7692	0,0000	0,0000	0,6441	0,1463	0,3186	0,2677	0,6915	0,1585
0,6923	0,0000	0,0000	0,0000	0,1463	0,9387	0,8548	0,8521	0,2176

D-Min Max normalizasyon yönteminde veri setindeki en küçük veri 0,1 değerini alır, en büyük veri ise 0,9 değerini alır. Bu yöntem ile veriler Denklem 4.2'de belirtilen eşitsizlik kullanılarak 0,1 ile 0,9 arasına indirgenir.

$$x' = 0,8 \times \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} + 0,1 \quad (4.2)$$


Bu formülde x' normalize edilmiş veriyi, x_i girdi değerini, $x_{\min}$ girdi verilerindeki en küçük değeri, $x_{\max}$ girdi verilerindeki en büyük değeri ifade etmektedir. D-Min Max

Normalizasyon yöntemi ile normalize edilmiş örnek veriler Tablo 4.8.'de gösterilmiştir.


Tablo 4.8. D-Min Max Yöntemiyle Normalize Edilmiş Örnek Veri

Kumaş Türü	Kumaş Özellik	Boya Cinsi	Elyaf Karışım	İplik	Ekonomik güven endeksi	Tüketici Güven endeksi	TÜFE	Kumaş Sipariş Miktarı
0,7154	0,1000	0,1000	0,2763	0,1195	0,6021	0,6039	0,1984	0,1000
0,1000	0,1000	0,1000	0,1000	0,1195	0,6879	0,4629	0,2327	0,1253
0,5923	0,1000	0,4200	0,1949	0,6463	0,5736	0,3766	0,4984	0,1444
0,5308	0,5000	0,1000	0,4932	0,2171	0,5433	0,4510	0,7566	0,5703
0,2231	0,5000	0,5800	0,2085	0,2171	0,3360	0,3705	0,8266	0,8771
0,4077	0,1000	0,1000	0,5068	0,2366	0,3360	0,3705	0,8266	0,8790
0,6538	0,1000	0,1000	0,1000	0,2171	0,8510	0,7838	0,7817	0,2741
0,4077	0,2333	0,5800	0,1407	0,1585	0,5158	0,5131	0,4294	0,4289
0,7154	0,2333	0,1000	0,1000	0,3732	0,1440	0,4414	0,6462	0,9000

MATLAB 2018B sürümü yazılımın Neural Network Toolbox'ı kullanılarak kullanılarak iki farklı yöntemle normalize edilmiş verilerin yapay sinir ağı performans sonuçları karşılaştırılmıştır. Min Max normalizasyon yönteminin ysa performansı Şekil 4.3.'de D-Min Max normalizasyon yönteminin ysa performansı ise Şekil 4.4.'de gösterilmiştir.



Şekil 4.3. Min Max Min Max Normalizasyon Yöntemi ile YSA Performansı



Şekil 4.4. D-Min Max Normalizasyon Yöntemiyle YSA Performansı

Yukarıdaki grafikler incelendiğinde Min Max Normalizasyon yönteminin %97,55 performans ile daha başarılı sonuç verdiği tespit edilmiştir. Bu sebepten uygulamada verilerin normalize edilmesi için Min Max Normalizasyon yöntemine karar verilmiştir.

Yapay Sinir Ağı MATLAB Uygulaması

Talep tahmini çalışmalarında geri yayılım algoritması en sık kullanılan yöntemdir. Bu sebepten ötürü talep tahmini çalışmasında yöntem olarak çok katmanlı ileri beslemeli geri yayılım algoritması tercih edilmiştir.

Erkek departmanına ait 4 yıllık arasında toplamda 1800 adet kumaş sipariş verisi kullanılmıştır. Bu verilerin 1440 (%80) tanesi yapay sinir ağının eğitilmesinde, 360 (%20) tanesi de performansın test edilmesinde kullanılmıştır.

4.1.1. Öğrenme katsayısı ve momentum katsayısının belirlenmesi

Yapay sinir ağı modelinde öğrenme katsayısı, momentum katsayısı ve hücre sayısı tahmin sonuçlarını etkilemektedir (Sarı, 2016). Öğrenme katsayısı ağırlıkların değişim miktarlarını belirlemektedir. Geçmiş uygulamalarda genellikle 0,2-0,4 arasında değerler kullanılmıştır. Ama bu değerler problemde göre farklılık gösterebilmektedir. Bazı uygulamalar da ise 0.6 değeri aldığında en başarılı sonuç verdiği gözlemlenmiştir (Öztemel, 2003).

Çevrim sayısı 1000, nöron sayısı 8, momentum katsayısı 0,8 sabit tutularak öğrenme katsayısında 0,1'den 0,9'a kadar denemeler yapılmıştır. Denemelerdeki yapay sinir ağı performansları Tablo 4.9.'da belirtilmiştir. Tablo 4.9.'daki veriler incelendiğinde öğrenme katsayısı 0,8 olduğunda %96,66 performansla daha iyi sonuç verdiği tespit edilmiştir.

Tablo 4.9. Öğrenme Katsayısı Denemelerindeki YSA Performansı

Öğrenme Katsayısı	Momentum Katsayısı	Çevrim Sayısı	Yapay Sinir Ağı Performansı			
			Training	Validation	Test	All
0,1	0,8	1000	0,91888	0,89888	0,87696	0,90866
0,2	0,8	1000	0,89775	0,86091	0,86506	0,8885
0,3	0,8	1000	0,92951	0,92686	0,93022	0,92909
0,4	0,8	1000	0,89665	0,89917	0,88576	0,89561
0,5	0,8	1000	0,91381	0,91851	0,91439	0,91419
0,6	0,8	1000	0,91193	0,85508	0,89108	0,90035
0,7	0,8	1000	0,88374	0,85479	0,8788	0,87889
0,8	0,8	1000	0,9676	0,96586	0,95933	0,96605
0,9	0,8	1000	0,89052	0,87086	0,85567	0,88265

Momentum katsayısı ise önceki iterasyonun değişiminin belirli bir oranının sonraki değişim miktarını eklemesi olarak tanımlanır. Geçmiş uygulamalarda bu değerin 0.6 ile 0.8 arasında en başarılı sonuç verdiği gözlemlenmiştir (Öztemel, 2003).

Çevrim sayısı 1000, nöron sayısı 8, öğrenme katsayısı 0,8 sabit tutularak momentum katsayısında 0,1'den 0,9'a kadar denemeler yapılmıştır. Denemelerdeki yapay sinir ağı performansları Tablo 4.10.'da belirtilmiştir. Tablo 4.10.'daki veriler incelendiğinde momentum katsayısı 0,9 olduğunda %92,89 performansla daha iyi sonuç verdiği tespit edilmiştir.

Tablo 4.10. Momentum Katsayısı Denemelerindeki YSA Performansı

Öğrenme Katsayısı	Momentum Katsayısı	Çevrim Sayısı	Yapay Sinir Ağı Performansı			
			Training	Validation	Test	All
0,8	0,1	1000	0,85216	0,83657	0,8151	0,8431
0,8	0,2	1000	0,80591	0,80345	0,74364	0,79764
0,8	0,3	1000	0,83219	0,8151	0,79316	0,82355
0,8	0,4	1000	0,84833	0,86102	0,82035	0,84456
0,8	0,5	1000	0,89709	0,89448	0,8773	0,89351
0,8	0,6	1000	0,88719	0,87945	0,88316	0,88508
0,8	0,7	1000	0,91683	0,89916	0,90711	0,9122
0,8	0,8	1000	0,92427	0,90923	0,89151	0,91717
0,8	0,9	1000	0,9363	0,91394	0,91009	0,92895

4.1.2. Nöron sayısının belirlenmesi

Nöron sayısının az olduğunda yapay sinir ağının genelleme yeteneğini artmaktadır. Gereğinden daha çok olması durumunda ağın verileri ezberlemesine sebep olabilmektedir. (Sarı, 2016). 1-20 arasında nöron sayıları seçilerek denemeler yapılmıştır. Denemelerdeki yapay sinir ağı performansları Tablo 4.11.'de belirtilmiştir. Tablo 4.11.'deki veriler incelendiğinde nöron sayısı 20 olduğunda %98,59 performansla daha iyi sonuç verdiği tespit edilmiştir.

Tablo 4.11. Nöron Sayısı Demelerindeki YSA Performansı

Nöron Sayısı	Öğrenme Katsayısı	Momentum Katsayısı	Çevrim Sayısı	Yapay Sinir Ağı Performansı			
				Training	Validation	Test	All
1	0,8	0,9	1000	0,83195	0,82304	0,81749	0,82924
2	0,8	0,9	1000	0,88894	0,89333	0,8197	0,88296
3	0,8	0,9	1000	0,87063	0,84936	0,85541	0,86549
4	0,8	0,9	1000	0,92743	0,92008	0,92731	0,92629
5	0,8	0,9	1000	0,83907	0,82466	0,80623	0,83155
6	0,8	0,9	1000	0,88718	0,86801	0,87692	0,88286
7	0,8	0,9	1000	0,92717	0,90027	0,92499	0,92334

Tablo 4.11. (Devamı)


Nöron Sayısı	Öğrenme Katsayısı	Momentum Katsayısı	Çevrim Sayısı	Yapay Sinir Ağı Performansı			
				Training	Validation	Test	All
8	0,8	0,9	1000	0,89092	0,85999	0,8192	0,8762
9	0,8	0,9	1000	0,93393	0,89588	0,86208	0,92008
10	0,8	0,9	1000	0,92863	0,88694	0,88834	0,91644
11	0,8	0,9	1000	0,93376	0,92702	0,91729	0,93034
12	0,8	0,9	1000	0,88622	0,87484	0,80006	0,87495
13	0,8	0,9	1000	0,92243	0,88787	0,92693	0,91747
14	0,8	0,9	1000	0,93718	0,90736	0,89808	0,92805
15	0,8	0,9	1000	0,95414	0,94792	0,93332	0,94936
16	0,8	0,9	1000	0,94797	0,93856	0,93988	0,94481
17	0,8	0,9	1000	0,95425	0,93827	0,93482	0,94889
18	0,8	0,9	1000	0,96845	0,92223	0,95386	0,95929
19	0,8	0,9	1000	0,93477	0,92668	0,91985	0,93081
20	0,8	0,9	1000	0,98817	0,98192	0,9839	0,98591

4.1.3. Yapay sinir ağının eğitilmesi

Yapay sinir ağını eğitmek amacıyla MATLAB 2018B sürümü yazılımının Neural Network Toolbox'ı kullanılmıştır.


Erkek departmanına ait 4 yıllık arasında toplamda 1800 adet kumaş sipariş verisi kullanılmıştır. Bu verilerin 1440 (%80) tanesi yapay sinir ağının eğitilmesinde, 360 (%20) tanesi de performansın test edilmesinde kullanılmıştır. Eğitim için kullanılacak normalize edilmiş veriler sisteme girdi ve çıktı olarak yüklenir.

Veri yükleme yapıldıktan sonra Network alanından yapay sinir ağı oluşturulur. Ağ oluşturulurken ağ tipi, eğitim için girdi ve çıktı verisi, eğitim, performans fonksiyonu, öğrenme algoritmaları, katman sayısı, nöron sayısı, gizli hücre sayısı ve aktivasyon fonksiyonu girişleri yapılır. Yapılan girişler Şekil 4.5.'deki gibidir. Create butonu tıklanarak ağ oluşturulur.




Şekil 4.5. Matlab YSA Oluşturulma Ekranı

Oluşturulan yapay sinir ağı modeli Şekil 4.6.'daki gibidir.




Şekil 4.6. Yapay Sinir Ağı Modeli

Yapay sinir ağı oluşturulduktan sonra Train sekmesinden momentum katsayısı, öğrenme katsayısı ve çevrim sayısı gibi öğrenmesine etki eden faktörler için veri girişi Şekil 4.7.'deki gibi yapılır ve Train Network butonu tıklanarak ağı eğitilir.



Şekil 4.7. Yapay Sinir Ağı Eğitim Ekranı

Yapay sinir ağı eğitildikten sonra regrasyon grafiği Şekil 4.8.'deki gibidir. Bu grafiğe göre %98,59 performansla başarılı öğrenme gerçekleşmiştir.




Şekil 4.8. YSA Regrasyon Grafiği

4.1.4. Yapay sinir ağının test edilmesi

Ağı test etmek için eğitim verisinde yer almayan, ağı hiç görmediği veriler test verisi olarak ayrılmıştır. Bu veriler ağı iletilir ve ağı eğitimi esnasında, ağı tanımlamış olduğu ağırlık ve eşik değerlerini kullanarak daha önce hiç görmediği bu veriler için çıktılar üretir. (Arıkan Kargı, 2013)

Yapay sinir ağı eğitildikten sonra Simulate sekmesine Şekil 4.9.'daki gibi test girdi verisi seçilir. Veri seçildikten sonra Simulate Network butonu tıklanarak test edilmesi işlemi tamamlanır.



Şekil 4.9. Matlab Test Verisi Yükleme Ekran Görüntüsü

Test çıktı değerleri excele aktararak ile gerçek veriler karşılaştırılmıştır. Hata performansı Tablo 4.12.'de belirtilmiştir.

Ortalama kare hata(MSE), bir makine öğrenmesi modelinin, tahminleyicinin performansını ölçer, her zaman pozitif değerlidir ve MSE değeri sıfıra yakın olan tahminleyicilerin daha iyi bir performans gösterdiği söylenebilir

(www.veribilimcisi.com., 2022). Yapay sinir ağı modeli MSE değeri 0,001756 performansla başarılı bir tahminleme yapmıştır.

Tablo 4.12. Tahmini ve Gerçekleşen Kumaş Sipariş Verileri ve Hata Oranları

Ortalama Kare Hata	Ortalama Mutlak Yüzde Hata	Ortalama Mutlak Sapma
MSE	MAPE	MAD
0,001756	0,195875	0,030079

Witt ve Witt, MAPE değeri %10'un altındaki tahmin modelleri için "yüksek doğruluk" derecesinde, %10 ile %20 arasında ise doğru tahminler diye sınıflandırmıştır. Bununla birlikte Lewis, MAPE değeri %10'un altındaki tahmin modellerini "çok iyi", %10 ile %20 arasındaki tahmin modelleri için "iyi", %20 ile %50 arasındaki tahmin modelleri için "kabul edilebilir" ve %50'nin üzerinde olan modelleri ise "yanlış ve hatalı" olarak sınıflandırmıştır. (Aslay ve Özen, 2013)

BÖLÜM 5. TARTIŞMA VE SONUÇ

Tekstil sektöründe talep tahminini etkileyen birçok unsur bulunmaktadır. Tahminleme doğru yapılmadığında tedarik süreci olumsuz etkilenir. Bir modelin üretim gün süresini en çok kumaş tedarik süresi etkilemektedir. Kumaş Tedarik süresinde yapılacak olan iyileştirmeler modelin toplam üretim süresini ciddi anlamda azaltacaktır.

Yapılan doğru tahminleme çalışmaları ile tedarikçilere geçilecek olan siparişler önceden tanımlanabilir ve hazırlık süreci başlar. Eğer mevcut tedarikçi kapasitesi yeterli değil ise yeni tedarikçi arayışına girilir ya da tedarikçinin kapasitesini büyütmesi talep edilebilir.

Modellerin üretiminde kullanılacak kumaşlar zamanında üretilip tedarik edilemezse siparişler planlanan termin tarihine yetişmez. Bu durum ise müşteri memnuniyetsizliği ve sipariş kayıplarına sebep olabilmektedir.

Perakende sektörü genellikle hızlı satış eğilimindedir. Eğer bir müşteri talep ettiği bir modeli talep ettiği özelliklerde bulamaz ise rakip mağazaya yönelip ihtiyacını gidermektedir. Bu durum da mağazalar için satış kaybına sebep olmaktadır. Bu sebepten müşterinin ihtiyacını doğru tahmin etmek oldukça önemlidir (Güven, 2020).

Yapılan çalışmada şirketin erkek departmanına ait 4 yıllık kumaş sipariş verileri kullanılarak yapılan tahminlemede yapay sinir ağına ait geri yayılım algoritması kullanılmıştır. Kumaş sipariş miktarını etkileyen faktörleri tespit etmek için uzman kişilerle görüşülmüştür. Çalışmada ele alınan faktörler kumaş türü, özelliği, boya cinsi, iplik numarası, elyaf karışımı, ekonomik güven endeksi, tüketici güven endeksi ve TÜFE'dir.

Yapay sinir ağı modeli oluşturulurken öğrenme katsayısı, momentum katsayısı, nöron sayısı için çeşitli denemeler yapılarak %98,59 performansını veren ysa modeli tahminleme çalışmasında kullanılmıştır. Yapay sinir ağı modeli MSE değeri 0,001756 ve MAPE değeri %19 performans göstermiştir. MAPE değeri %10 ile %20 arasında olduğu için iyi bir tahminleme yapmıştır.

Sonraki çalışmalar için farklı yapıda yapay sinir ağları oluşturulup, farklı girdiler eklenerek tahminleme çalışması yapılabilir. Hammadde talep tahminlemesi çalışmasına tedarikçilerin kapasiteleri eklenerek tedarikçi kapasite planlaması çalışmaları yapılabilir.



KAYNAKLAR

- Álvarez-López, V., Campomanes-Álvarez, B., & Quirós, P. 2019. Hybrid machine learning methods for demand forecasting: consecutive application of classification and regression methods for the forecasting of periodic and non-continuous demand. In *Proceedings of the 2nd International Conference on Applications of Intelligent Systems*. New York, 1-6.
- Arıkan Kargı, V.S. 2013. Yapay Sinir Ağ Modelleri Ve Bir Tekstil Firmasında Uygulama. Uludağ Üniversitesi, Sosyal Bilimler Enstitüsü, Yöneyem Bilim Dalı, Doktora Tezi.
- Aslay, F. & Özen, Ü. 2013. Meteorolojik Parametreler Kullanılarak Yapay Sinir Ağları İle Toprak Sıcaklığının Tahmini . *Politeknik Dergisi* , 16 (4) , 139-145
- Ataseven, B. 2013. Yapay Sinir Ağları İle Öngörü Modellemesi. *Öneri Dergisi*, 10 (39), 101-115.
- Au, K.F., Choi, T.M., Yu, Y. 2008. Fashion retail forecasting by evolutionary neural networks. *International Journal of Production Economics*, 114(2): 615–630.
- Bi, J.W., Lia, H., Fan, Z.P. 2021. Tourism demand forecasting with time series imaging: A deep learning model. *Annals of Tourism Research*, 90: 103255.
- Boone, T., Ganeshan, R., Hicks, R., & Sanders, N. 2018. Can Google Trends Improve Your Sales Forecast? *Production and Operations Management*, 27(10), 1770-1774.
- Carbonneau, R., Laframboise, K., & Vahidov, R. 2008. Application of machine learning techniques for supply chain demand forecasting. *European Journal of Operational Research*, 184(3), 1140-1154.
- Dai, W., Chuang, Y.Y., Lu, C.J. 2015. A Clustering-based Sales Forecasting Scheme Using Support Vector Regression for Computer Server. *Procedia Manufacturing*, 2: 82-86.
- Ergün, S., & Şahin, S. 2017. İşletme Talep Tahmini Üzerine Literatür Araştırması. *Ulakbilge*, 469-487.
- Frank, C., Garg, A., Sztandera, L., & Raheja, A. 2003. Forecasting women's apparel sales using mathematical modeling. *International Journal of Clothing Science and Technology*, 15(2), 107-125.
- Fumi, A., Pepe, A., Scarabotti, L., Schiraldi, M.M. 2013. Fourier analysis for demand forecasting in fashion company. *International Journal of Engineering Business Management*, 5: 5-30.

- Gündüz, G. 2019. Derin Öğrenme İle Fotoğraftan Yaş Ve Cinsiyet Tespiti. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Güven, İ. 2020. Perakende Hazır Giyim Endüstrisinde Yapay Zeka Yöntemleri İle Talep Tahmini. Karabük Üniversitesi, Lisansüstü Eğitim Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Güven, İ., & Şimşir, F. 2020. Demand forecasting with color parameter in retail apparel industry using artificial neural networks (ANN) and support vector machines (SVM) methods. *Computers and Industrial Engineering*, 147.
- Güven, İ., Uygun, Ö., & Şimşir, F. 2021. Machine Learning Algorithms with Intermittent Demand Forecasting: An Application in Retail Apparel with Plenty of Predictors. *Textile and Apparel*, 31(2), 99-110.
- Huang, L., Zheng, W. 2021. Novel deep learning approach for forecasting daily hotel demand with agglomeration effect. *International Journal of Hospitality Management*, 98: 103038.
- Karaatlı, M. , Helvacıoğlu, Ö. C. , Ömürbek, N. & Tokgöz, G. 2012. Yapay Sinir Ağları Yöntemi İle Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat Ve İşletme Dergisi*, 8(17): 87-100.
- Karabay, G. 2006. Tekstil Sektöründe Tedarik Zinciri Uygulamalarının Mevcut Durumunun Belirlenmesi Ve Çözüm Önerileri. Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, Tekstil Mühendisliği, Yüksek Lisans Tezi.
- Katırcıoğlu, G. 2019. Denim Kumaşların Görüntü İşleme İle İncelenip Kumaş Hava Geçirgenliğinin Yapay Sinir Ağı İle Tahmin Edilmesi. Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Kaya, Ö., Öztürk, F. 2018. Tekstil ve Hazır Giyim Sanayinde Ana Firma-Tedarikçi İlişkileri. 2nd International Congress On Fashion -Art – Design. *Bilişim Teknolojileri Dergisi*, Paris, 75-87.
- Kayaalp, K., Süzen, A.A. 2018. Derin Öğrenme ve Türkiye'deki Uygulamaları. IKSAD Yayınevi, 11.
- Kızrak, M.A., Bolat, B. 2018. Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. *Bilişim Teknolojileri Dergisi*, 11(3): 263-286.
- Law, R., Li, G., Fong, D.K.C., Han, X. 2019. Tourism demand forecasting: A deep learning approach. *Annals of Tourism Research*, 75: 410-423.
- LeCun, Y., Bengio, Y., Hinton, G. 2015. Deep Learning. *Nature* 521, 436–444.
- Lolli, F., Gamberini, R., Regattieri, A., Balugani, E., Gatos, T., & Gucci, S. 2017. Single-hidden layer neural networks for forecasting intermittent demand. *International Journal of Production Economics*, 183, 116-128.
- Mezzogori, D., Zammori, Z. 2019. An Entity Embeddings Deep Learning Approach for Demand Forecast of Highly Differentiated Products. *Procedia Manufacturing*, 39: 1793-1800.

- Öztemel, E. 2003. Yapay Sinir Ağları. Birinci Baskı, Papatya Yayıncılık, İzmir, 1-231.
- Öztürk, K., Şahin, M. E. 2018. Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış . Takvim-i Vekayi , 6: 25-36
- Pacella, M., Papadia, G. 2021. Evaluation of deep learning with long short-term memory networks for time series forecasting in supply chain management. *Procedia CIRP*, 99: 604-609.
- Rabenasolo, B., Happiette, M., Boussu, F. 1997. Sales Forecasting Under Uncertain Environment Fuzzy Classification in Textile Distribution. *IFAC Proceedings Volumes*, 30(6): 1469-1474
- Rizvanche, S. 2020. Talep Tahmininde Makine Öğrenmesi Ve Zaman Serileri Temelli Bir Karar Destek Sistemi. Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Endüstri Mühendisliği, Yüksek Lisans Tezi.
- Saha, C., Lam, S.S., Boldrin, W. 2014. Demand forecasting for server manufacturing using neural networks. *Proceedings of the 2014 Industrial and Systems Engineering Research Conference*, Canada, 1031.
- Sakallı, H. 2007. Tekstil Sektöründe Lojistik Ve Tedarik Zinciri Yönetimi. Dokuz Eylül Üniversitesi, Sosyal Bilimler Enstitüsü, Toplam Kalite Yönetimi, Yüksek Lisans Tezi.
- Satoğlu, Ş.I., Eren, U. 2017. Perakende Giyim Sektöründe Yapay Sinir Ağları ile Talep Tahmini. *Endüstri-İşletme Kurultayı*, İstanbul, 63-68.
- Schmidhuber, J. 2015. Deep learning in neural networks: An overview. *Neural Networks*, 61: 85-117
- Sun, Z.L., Choi, T. M., Au, K. F., Yu, Y. 2008. Sales forecasting using extreme learning machine with applications in fashion retailing. *Decision Support Systems*, 46(1): 411-419.
- Tanizaki, T., Hoshino, T., Shimmura, T., & Takenaka, T. 2019. Demand forecasting in restaurants using machine learning and statistical analysis. *Procedia CIRP*, 79, 679-683.
- Thomas Ng, S., Skitmore, M., & Wong, K. F. 2008. Using genetic algorithms and linear regression analysis for private housing demand forecast. *Building and Environment*, 43(6), 1171-1184.
- Thomassey, S. 2010. Sales forecasts in clothing industry: The key success factor of the supply chain management. *International Journal of Production Economics*, 128(2): 470 - 483.
- Thomassey, S., Hapiette, M. 2007. A neural clustering and classification system for sales forecasting of new apparel items. *Applied Soft Computing.*, 7(4): 1177-1187.

- Torkul, O., Yılmaz, R., Selvi, İ. H., & Cesur, M. R. 2016. A real-time inventory model to manage variance of demand for decreasing inventory holding cost. *Computers and Industrial Engineering*(102), 435-439.
- Tsao, Y.C., Chen, Y.K., Chiu, S.H., Lu, J.C., & Vu, T.L. 2021. An innovative demand forecasting approach for the server industry. *Technovation*.
- Xu, C., Ji, J., Liu, P. 2018. The station-free sharing bike demand forecasting with a deep learning approach and large-scale datasets. *Transportation Research Part C: Emerging Technologies*, 95: 47-60.
- Yavuz, S., Deveci, M. 2015. İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağı Performansına Etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* , 0 (40): 167-187.
- Y. Zhang, G. Li, B. Muskat, R. Law 2020. Tourism demand forecasting: A decomposed deep learning approach. *Journal of Travel Research*, 60(5): 981-997.
- Yazıcı, Ü.H. 2010. Yapay Sinir Ağları İle Banka Müşterisi Bekleme Süresi Tahmini. *Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi*.
- Yu, Y., Choi, T., Hui, C. 2011. An intelligent fast sales forecasting model for fashion products. *Expert Systems with Applications*, 38(6): 7373–7379.
- Zhang, B., Li, N., Shi, F., Law, R. 2020. A deep learning approach for daily tourist flow forecasting with consumer search data. *Asia Pacific Journal of Tourism Research*, 25(3): 323-339.
- www.wowslides.com., Erişim Tarihi: 05.01.2022.
- www.pythondunyasi.com., Erişim Tarihi: 05.01.2022.
- www.tekstilsayfasi.blogspot.com., Erişim Tarihi: 05.01.2022.
- www.data.tuik.gov.tr., Erişim Tarihi: 05.01.2022.
- www.veribilimcisi.com., Erişim Tarihi: 05.01.2022.

ÖZGEÇMİŞ

Adı Soyadı :Büşra Engin

ÖĞRENİM DURUMU

Derece	Eğitim Birimi	Mezuniyet Yılı
Yüksek Lisans	Sakarya Üniversitesi / Fen Bilimleri Enstitüsü / Endüstri Mühendisliği	Devam Ediyor
Lisans	Sakarya Üniversitesi / Mühendislik Fakültesi / Endüstri Mühendisliği	2017
Lise	Validebağ Anadolu Sağlık Meslek Lisesi	2011

İŞ DENEYİMİ

Yıl	Yer	Görev
2018-Halen	Taha Giyim	Strateji ve Süreç Geliştirme Uzmanı

YABANCI DİL

İngilizce

HOBİLER

Türk Musikisi, Ud Çalmak