

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
ENDÜSTRİ MÜHENDİSLİĞİ BİLİM DALI

**BİR ÜRETİM İŞLETMESİNDE YAPAY SİNİR AĞLARI
VE ANFİS METODUYLA TALEP TAHMİNLEMESİ**

Yüksek Lisans Tezi

Tezi Hazırlayan
Selman GÜLLER

İstanbul, 2024

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
ENDÜSTRİ MÜHENDİSLİĞİ BİLİM DALI

**BİR ÜRETİM İŞLETMESİNDE YAPAY SİNİR AĞLARI
VE ANFİS METODUYLA TALEP TAHMİNLEMESİ**

Yüksek Lisans Tezi

Tezi Hazırlayan
Selman GÜLLER

Öğrenci No
2120006001

ORCID ID
0000-0001-0000-000X

Danışman
Dr. Öğr. Üyesi Furkan DİŞKAYA

İstanbul, 2024

YEMİN METNİ

Yüksek Lisans Tezi olarak sunduğum “**Bir Üretim İşletmesinde Yapay Sinir Ağları ve Anfis Metoduyla Talep Tahminlemesi**” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere uygun şekilde tarafımdan yazıldığını, bu tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, yararlandığım eserlerin tamamının kaynaklarda gösterildiğini ve çalışmamın içinde kullanıldıkları her yerde bunlara atıf yapıldığını, patent ve telif haklarını ihlal edici bir davranışımın olmadığını belirtir ve bunu onurumla doğrularım. 28.08.2024

Selman GÜLLER

T.C.
İSTANBUL BEYKENT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜ
TEZLİ YÜKSEK LİSANS SINAV TUTANAĞI

28.../08/2024

Enstitümüz *Endüstri Mühendisliği* Anabilim Dalı *Endüstri Mühendisliği* Programı Yüksek Lisans öğrencilerinden **2120006001** numaralı **Selman GÜLLER**'in "İstanbul Beykent Üniversitesi Eğitim-Öğretim Yönetmeliği"nin ilgili maddesine göre hazırlayarak Enstitümüze teslim ettiği "**Bir Üretim İşletmesinde Yapay Sinir Ağları ve ANFİS Metoduyla Talep Tahminlemesi**" konulu tezini, Yönetim Kurulumuzun 14/05/2024 tarih ve 2024/22 sayılı toplantısında seçilen ve ve Taksim yerleşkesinde toplanan biz jüri üyeleri huzurunda, İstanbul Beykent Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 29. maddesinin 3. fıkrası gereğince 45 dakika süre ile aday tarafından savunulmuş ve sonuçta adayın tezi hakkında "**OYBİRLİĞİ**" ile "**KABUL**" kararı verilmiştir.

İşbu tutanak, 2 nüsha olarak hazırlanmış ve Enstitü Müdürlüğü'ne sunulmak üzere tarafımızdan düzenlenmiştir.

DANIŞMAN
Dr. Öğr. Üyesi Fu*** Dİ***
(İstanbul Beykent Üniversitesi)

ÜYE
Dr. Öğr. Üyesi Ve*** Ze*** YE***
(İstanbul Beykent Üniversitesi)

ÜYE
Dr. Öğr. Üyesi Şe*** EM***
(İstanbul Üniversitesi)

Adı Soyadı : Selman GÜLLER
Danışmanı : Dr. Öğr. Üyesi Furkan DİŞKAYA
Derecesi ve Tarihi : Yüksek Lisans (Tezli), 2024
Alanı : Endüstri Mühendisliği
Anahtar Kelimeler : Üretim İşletmesi, Yapay Sinir Ağları, ANFİS Metodu, Talep Tahminlemesi.

ÖZ

BİR ÜRETİM İŞLETMESİNDE YAPAY SİNİR AĞLARI VE ANFİS METODUYLA TALEP TAHMİNLEMESİ

Çalışmamızda yer alan firmamızın satışları genellikle Avrupa ülkeleri ve çeşitli ülkeler de olduğu için bir ülkenin satışları azalırken diğer ülkenin satışları artış göstermektedir. Bu faktörlerin incelenmesi, yapay sinir ağları (YSA) ve ANFİS gibi yöntemlerle talep tahmini yapılırken kullanılan modellerin doğruluğunu artırabilir ve işletmenin stratejik planlamasına katkı sağlayacağı düşünülmektedir. Çalışmada kullanılan veriler firmamız tarafından 2 yıl boyunca satış yapılan gerçek miktarlardır. Veriler ERP (Enterprise Resource Planning) programı olan SAP Business One üzerinden alınmıştır. Bu çalışmada hem YSA hem de ANFİS yöntemlerinin kullanılması, model performansının karşılaştırılması, güçlü ve zayıf yönlerin belirlenmesi, daha kapsamlı analiz yapılması, farklı uygulama alanlarının incelenmesi, akademik ve pratik katkı sağlanması ve daha güvenilir tahminler elde edilmesi gibi birçok önemli nedeni kapsamaktadır. Bu yaklaşımla tez çalışmasının bilimsel değerini artırmakta ve tahmin doğruluğunu maksimize etmek amaçlanmıştır.

Sonuç olarak, her iki modelin de belirli veri setlerinde başarılı tahminler yapabildiği ve farklı eğitim oranlarına göre performanslarının değiştiği gözlemlenmiştir. ANFİS modeli, genellikle daha yüksek tahmin doğruluğu ve istikrar sunarken, YSA modeli de belirli koşullarda etkili sonuçlar verebilmektedir. Bu çalışma, zaman serisi tahminlerinde hem ANFİS hem de YSA'nın önemli yöntemler olduğunu ve belirli durumlarda birbirini tamamlayabileceklerini göstermektedir. Bu bulgular, her iki yöntemin de zaman serisi tahminlerinde başarılı bir şekilde kullanılabileceğine ve seçilecek yöntemin veri setinin yapısına bağlı olarak değişebileceğine işaret etmektedir.

Name and Surname : Selman GÜLLER
Supervisor : Asst. Prof. Dr. Furkan DİŞKAYA
Degree and Date : Master's (Thesis), 2024
Major : Industrial Engineering
Keywords : Production Enterprise, Artificial Neural Networks,
ANFIS Method, Demand Forecasting.

ABSTRACT

DEMAND FORECASTING IN A MANUFACTURING BUSINESS WITH ARTIFICIAL NEURAL NETWORKS AND ANFIS METHOD

Since the sales of our company in our study are generally in European countries and various other countries, while the sales of one country decrease, the sales of the other country increase. Examining these factors can increase the accuracy of the models used in demand forecasting using methods such as artificial neural networks (ANN) and ANFIS and is thought to contribute to the strategic planning of the business. The data used in the study are the actual amounts sold by our company for 2 years. The data was taken from SAP Business One, an ERP (Enterprise Resource Planning) program. The use of both ANN and ANFIS methods in this study covers many important reasons such as comparing model performance, determining strengths and weaknesses, performing more comprehensive analysis, examining different application areas, providing academic and practical contributions and obtaining more reliable predictions. With this approach, it is aimed to increase the scientific value of the thesis study and maximize the prediction accuracy.

As a result, it has been observed that both models can make successful predictions on certain datasets and that their performance varies depending on the training ratio. The ANFIS model generally provides higher prediction accuracy and stability, while the ANN model can deliver effective results under specific conditions. This study demonstrates that both ANFIS and ANN are valuable methods for time series forecasting and can complement each other in certain situations. These findings suggest that both methods can be effectively used for time series forecasting and that the choice of method may depend on the structure of the dataset.

İÇİNDEKİLER

Sayfa No.

ÖZ

ABSTRACT

TABLolar LİSTESİ	iv
ŞEKİLLER LİSTESİ	v
KISALTMALAR	vi
SÖZLÜK.....	vii
GİRİŞ.....	1

1. LİTERATÜR TARAMASI

2. ÜRETİM VE ÜRETİM YÖNETİMİ

2.1. Üretim ve Üretim Yönetiminin Tanımı	15
2.2. Üretim Sistemleri Tasarım ve İşleyişi	15
2.3. Üretim Yönetiminin Amaçları.....	16
2.4. Stok Maliyeti ve Yönetimi.....	16
2.4.1. Envanter Yönetimi	17
2.4.2. Envanter Yönetiminin Önemi	17
2.4.3. Envanter Yönetiminde Etkinlik İlkeleri	18
2.4.4. Stok Çeşitleri.....	19
2.5. Üretim Planlama	20
2.5.1. Ana Üretim Programı.....	21
2.5.2. Malzeme İhtiyaç Planlaması	21
2.5.2.1. Malzeme İhtiyaç Planlaması Girdileri	22
2.5.2.2. Malzeme İhtiyaç Planlaması Çıktıları.....	22
2.5.3. Kapasite İhtiyaç Planlaması	23
2.6. Üretim Kaynakları Planlaması.....	23
2.7. İş İstasyonlarının Düzenlenmesi ve Bakımı.....	24
2.8. Kalite Kontrolü	25

3. TALEP TAHMİNLEMESİ

3.1. Talep Tahmini Kavramı.....	26
3.2. Talep Tahmin Prensipleri	27
3.3. Talep Tahmin Aşamaları	27
3.4. Talep Tahmin Yöntemleri.....	28
3.4.1. Nitel (Kalitatif) Talep Tahmin Yöntemleri	28
3.4.1.1. Delphi Tekniği	28
3.4.1.2. Uzmanların Görüşleri Yöntemi.....	29
3.4.1.3. Pazar Araştırması Yöntemi	29
3.4.1.4. Satış Elemanlarının Görüşleri Yöntemi	29
3.4.1.5. Yaşam Eğrilerinin Benzeşimi Yöntemi	29
3.4.2. Nicel (Kantitatif) Talep Tahmin Yöntemleri	30
3.4.2.1. İlişkiye Dayalı (Nedensel) Yöntemler	30
3.4.2.2. Zaman Serisi Yöntemleri	31
3.4.3. Yapay Zeka Tabanlı Yöntemler	33
3.5. Tahmin Doğruluğunun Ölçümü	33
3.6. Talep Tahmin Yönteminin Seçimi.....	34
3.7. Yapay Sinir Ağları.....	35
3.7.1. Tarihsel Gelişim	35
3.7.2. Yapay Sinir Ağlarının Kullanım Alanları	36
3.7.3. Yapay Sinir Ağları Yapısı.....	36
3.7.4. Yapay Sinir Ağlarının Genel Özellikleri.....	37
3.7.5. Yapay Sinir Ağlarının Avantajları	39
3.7.6. Yapay Sinir Ağlarının Dezavantajları	40
3.7.7. Yapay Sinir Ağlarında Öğrenme.....	41
3.7.7.1. Gözetimli Öğrenme.....	41
3.7.7.2. Gözetimsiz Öğrenme.....	42
3.7.8. Yapay Sinir Ağlarında Öğrenme Kuralları	42
3.7.8.1. Hebb Kuralı.....	42
3.7.8.2. Hopfield Kuralı	43
3.7.8.3. Kohonen Kuralı.....	43
3.7.8.4. Delta Kuralı.....	43

3.7.9. Yapay Sinir Ağı Çeşitleri	44
3.7.9.1. İleri Beslemeli Ağlar	44
3.7.9.2. Geri Beslemeli Ağlar	45
3.7.10. Yapay Sinir Ağları Çalışma Prosedürü	45
3.7.11. Yapay Sinir Ağları ve Tahmin Modelleri	46
3.8. ANFIS Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi	46
3.8.1. ANFIS Mimarisi	48
4. UYGULAMA	
4.1. Firma Tanıtımı.....	51
4.2. Araştırmanın Modeli	52
4.3. Talebi Etkileyen Faktörler	53
4.4. Verilerin Toplanması.....	53
4.4.1. Veri Seti Açıklaması	54
4.4.2. Veri İşleme Aşamaları.....	55
4.4.3. Veri Setini Haftalık Olarak Yeniden Düzenleme ve Ölçeklendirme	56
4.5. Yapay Sinir Ağları ile Talep Tahmini Uygulaması	56
4.5.1. YSA Model Oluşturma ve Eğitim	56
4.5.2. YSA Model Değerlendirme	57
4.5.3. YSA Sonuçların Görselleştirilmesi ve Tablo Halinde Sunulması	57
4.6. ANFIS ile Talep Tahmini Uygulaması.....	60
4.6.1. ANFİS Kütüphanesinin Oluşturulması	61
4.6.2. Model Tanımlama: ANFIS (Adaptive Neuro-Fuzzy Inference System)	62
4.6.3. ANFİS Modeli Derleme ve Eğitim	62
4.7. Anfis ve YSA Tahminlerinin Karşılaştırılması.....	64
4.7.1. YSA Analizleri.....	65
4.7.2. ANFİS Model Tanımlama Analizleri	65
4.7.3. ANFİS Modeli Derleme ve Eğitim Analizleri.....	65
4.7.4. ANFİS ve YSA Tahminlerinin Karşılaştırılması Analizleri	66
SONUÇ	68
KAYNAKÇA.....	76

TABLolar LİSTESİ

	Sayfa No.
Tablo 1. Model Tahmin Sonuçları Tablosu	57
Tablo 2. YSA Metrikler	58
Tablo 3. Tahminler.....	60
Tablo 4. ANFİS Metrikler.....	60
Tablo 5. ANFİS ve YSA Tahminlerinin Karşılaştırılması Tablosu	67
Tablo 6. ANFİS ve YSA Metriklerinin Karşılaştırılma Tablosu	67

ŞEKİLLER LİSTESİ

	Sayfa No.
Şekil 1. Bulanık Çıkarım Sistemi	48
Şekil 2. Anfis Mimarisi	48
Şekil 3. Tahmin Değerleri (%70 Eğitim Verisi).....	58
Şekil 4. Tahmin Değerleri (%80 Eğitim Verisi).....	59
Şekil 5. Tahmin Değerleri (%80 Eğitim Verisi ve %70 Eğitim Verisi).....	59
Şekil 6. Tahmin Değerleri (%70 Eğitim Verisi).....	63
Şekil 7. Tahmin Değerleri (%80 Eğitim Verisi).....	64
Şekil 8. Tahmin Değerleri (%80 Eğitim Verisi ve %70 Eğitim Verisi).....	64
Şekil 9. ANFİS ve YSA Tahminlerinin Karşılaştırılması Analiz Sonuçları	66

KISALTMALAR

AD	: Average Deviation (Ortalama Devinim)
ANN	: Artificial Neural Network (Yapay Sinir Ağları)
ANFIS	: Adaptive Network Based Fuzzy Inference System (Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi)
Cor	: Korelasyon
EBNM	: Euclidean Based Normalization Method (Öklid Tabanlı normalizasyon)
LBNM	: Line Based Normalization Method (Satır Tabanlı Normalizasyon Metodu)
Min-Mak	: Minimum-Maksimum
MLP	: Multi Layer Perceptron (Çok Katmanlı Nöron)
MSE	: Mean Squared Error (Ortalama Karesel Hata)
P	: İstatistiksel olasılık
R²	: İstatistiksel değerlendirme kriteri
Var	: Varyans
YSA	: Yapay Sinir Ağları

SÖZLÜK

ANFİS: Uyarlanabilir Nöro Bulanık Çıkarım Sistemi (ANFIS), hibrit bir akıllı sistem yaratmayı amaçlayan bulanık mantık ve sinir ağı metodolojilerinin bir birleşimini temsil etmektedir. ANFIS, her iki paradigmanın öğrenme yeteneklerini birleştirerek uyarlanabilir modellemeyi kolaylaştırır ve karmaşık ve doğrusal olmayan işlevlere yaklaşmasını sağlayan yazılımdır.

Envanter: Üretim sistemi tarafından üretilen ürünlerin üretimine doğrudan veya dolaylı olarak katılan tüm fiziksel malların miktarı veya parasal değeri ile ölçülür. Envanter seviyeleri, belirli sektörlerde varlıkların ve işletme sermayesinin önemli bir bileşenidir. Dolayısıyla işletmeler için önemlidir. Stok yönetiminin en önemli görevleri, üretim ve depolama miktarlarını planlamak, kontrol etmek ve sorunları ortadan kaldırmaktır.

Talep tahmini: Gelecekte talep edilecek mal ve hizmet miktarını tahmin etmektedir. Mal ve hizmetlere yönelik gelecekteki talebin tahmini, tüm işletme tahminlerinin başlangıç noktasıdır ve diğer işlevler için temel veriler sağlamaktadır.

Üretim: Bir şirketin küresel rekabette başarılı olabilmesi, bu gelişmeleri takip etmesine ve uygulamasına bağlıdır. Üretim, doğal kaynakları insan ihtiyaçlarını en iyi şekilde karşılayan mal ve hizmetlere dönüştüren fiziksel, kimyasal ve mekanik süreçler bütünü olarak tanımlanabilir.

Üretim yönetimi: Üretim faaliyetlerinin planlanması, koordinasyonu ve yürütülmesini içerir. Üretim yönetiminin amacı, kaynakların kullanımını optimize etmek, kayıpları en aza indirirken verimli çalışmak ve kaliteyi istenilen düzeye çıkarmaktır. Diğer bir ifadeyle üretim yönetimi, istenilen kalite ve standartta mal ve hizmetlerin istenilen zamanda ve en düşük maliyetle elde edilmesi için gerekli kararları içeren bir işletme fonksiyonudur.

Yapay sinir ağıları: Beynin işlevleri yerine getirme yeteneğini modelleyebilen sistemler olarak tanımlanabilir. Yapay sinir ağıları, genellikle katmanlar halinde düzenlenmiş yapay sinir hücrelerinin birbirine bağlanmasıyla oluşturulur. Beynin bilgi işleme işlevine göre yapay sinir ağıları, belli bir öğrenme süresinden sonra bilgiyi genelleme ve depolama yeteneğine mantık tabanlı yazılımlardır.



GİRİŞ

Bu bölümde çalışmanın önemi, amacı ve özgün değeri gibi kavramlarına yer verilecektir.

Hızla değişen teknolojinin yarattığı belki de en büyük sorunlardan biri daha fazla veri işleme ihtiyacıdır. Günümüz ürünlerinin daha az enerji tüketmesinin, daha konforlu olmasının ve daha fazlasını yapmasının nedeni, bu ürünlerin tasarımının, kontrolünün ve kullanımının açıklanması için daha fazla veri gerektirmesidir. Tıbbi cihazlardan havacılığa, tarımdan kimyaya kadar insan yorumu olmadan programlar uygulanmalı ve yorumlanmalıdır. Büyük çeşitlilik ve yapısal farklılıklar, veri işlemeyi zorlaştırır. Veri setindeki semboller ve sayısal olmayan nicelikler gibi nedenler, veri işlemede aşılması gereken ilk engellerdir. Yapay zekâ uygulamaları doğrusal olmayan problemlerin çözümünde oldukça popüler yöntemler olsa da verilerin yapısı sonuçları doğrudan etkileyen faktörlerden biri olmaktadır. Yapay zekâ uygulamalarına katılabilmek için veri yapılarının standardize edilmesi gerekmektedir. Normalleştirme, veri kümesindeki değerleri yapay zekanın aktarım işlevine uygun hale getirmektedir. Bu çalışmanın amacı, gelecek dönem talep tahmin oranını revize etmek, malzeme talep planlama, üretim planlama ve bütçe planlama verimliliğini artırmak ve optimal talep tahmin değerini elde etmek için talep tahminini YSA ve ANFIS yöntemleri kullanarak elde etmektedir.

Bu çalışmada, talep tahmin problemi için yeni bir normalizasyon yöntemi geliştirilmiş ve önerilmiştir. Önerilen yöntem yapay zeka uygulamaları için özel olarak geliştirilmiştir. Geliştirilen yöntemi test etmek için yaygın olarak kullanılan iki yapay zeka tekniği, uyarlanabilir ağ tabanlı bulanık çıkarım sistemi (ANFIS) ve yapay sinir ağı (YSA) kullanılmıştır. Ayrıca literatürdeki çoğu makale ve belgede incelenerek çalışmamızda kullanılmıştır. Geliştirilen yöntem sadece bir normalleştirme yöntemi olmayıp aynı zamanda veri normalleştirme için yeni bir bakış açısı sağlamaktadır. Lineer normalizasyon modelinin performansının klasik modellerle karşılaştırılabilir olması, önerilen modelin literatürde kullanılan klasik normalizasyon yöntemlerine yeni bir alternatif sağlayabileceğini düşündürmektedir.

Satır tabanlı normalleştirme yapıldığında, veri setindeki özellik vektörleri farklı birimlere sahip olabileceğinden, özellikler önce üniform değildir ve daha sonra

normalize edilmektedir. Bu, birim sorunlarını ortadan kaldırır ve değerler saf sayılar haline gelmektedir. Önerilen yöntem test edilirken, sınıflandırma veri setlerindeki olası sonuçları görmek için sadece talep tahmini veri setleri değil, literatürde yaygın olarak bulunan sınıflandırma veri setleri de kullanılmaktadır. Veri kümelerinin sınıflandırılmasındaki başarısı da modelin bu tür veri yapıları için kullanılabileceğini göstermektedir. Geliştirilen yöntem ile klasik yöntemler arasındaki performans farkı karşılaştırılmış ve literatürde kullanılan matematiksel istatistiksel değerlendirme kriterleri kullanılarak değerlendirilmiştir. Çalışmada önerilen yöntemin ANFIS ve YSA performansını iyileştirmesi ve sonuçlarının literatürde kullanılan klasik modellerle karşılaştırılabilir olması yöntemin başarısı olarak değerlendirilebilir.

Bu çalışmada bir üretim işletmesinde yapay sinir ağları ve anfis metoduyla talep tahminlemesi yapılması amaçlanmaktadır. Çalışmamızın birinci bölümde alanyazın taraması yapılarak literatür bölümüne yer verilmiştir. İkinci bölümde yapılacak uygulama kapsamında üretim ve üretim yönetiminin tanımı, üretim sistemleri tasarım ve işleyişi, üretim yönetiminin amaçları, stok maliyeti ve yönetimi, üretim planlama, üretim kaynakları planlaması, iş istasyonlarının düzenlenmesi ve bakımı, kalite kontrolü gibi teorik kavramlar açıklanmaya çalışılmıştır. Üçüncü bölümde talep tahmini kavramı, talep tahmin prensipleri, talep tahmin aşamaları, talep tahmin yöntemleri, tahmin doğruluğunun ölçümü, talep tahmin yönteminin seçimi, yapay sinir ağları ve uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFS) teorik kavramlarına yer verilmektedir. Çalışmamızın son bölümünde ise uygulama talep tahmin problemi için yeni bir normalizasyon yöntemi geliştirilmiş ve önerilmiştir. Önerilen yöntem yapay zekâ uygulamaları için özel olarak geliştirilmiştir. Geliştirilen yöntemi test etmek için yaygın olarak kullanılan iki yapay zekâ tekniği, uyarlanabilir ağ tabanlı bulanık çıkarım sistemi (ANFIS) ve yapay sinir ağı (YSA) kullanılmıştır.

1. LİTERATÜR TARAMASI

Üretim, insan ihtiyaçlarını karşılamak için enerji ve emek gibi çeşitli girdi süreçlerinden üretilen ürün veya hizmetler biçimindeki çıktılardır. Üretim, bir dizi girdiyi yeterli nitelik ve nicelikte nihai mal ve hizmetlere dönüştürmeyi amaçlayan katma değerli bir süreçtir. Bu unsurlar insan gücü, hammadde, sermaye, enerji ve bilgi olarak tanımlanabilir. Bu, tüm ekonomilerin ve toplumların temel bir gereğidir. Tüketici ihtiyaçlarını karşılayan mal ve/veya hizmet üretme sürecidir. Üretim yönetimi; Malzemelerin belirli bir sürede yüksek kaliteli ve düşük maliyetli üretim elde etmek için onu en uygun şekilde kullanmakta yatmaktadır. Üretim yönetimi, işletmenin mevcut kaynaklarının, bu kaynaklardan gerekli miktarda ve kalitede ürün üretmek için etkin bir şekilde kullanılmasına karar verme sürecini ifade etmektedir. Üretim yönetiminin amacı, kaynakları olabildiğince verimli kullanmak, kayıpları en aza indirmek ve bunları gerekli kalite seviyesine getirmektir. Yapay sinir ağları, insan beyninin çalışma prensiplerinden yararlanılarak geliştirilmiştir. Nöronlar arası iletişime dayalı bu yapıda, düğümler arasında farklı ağırlıklarda bağlantılar vardır. Bunlar, her biri ayrı bir belleğe sahip olan ve bu bağlantılarla birbirine bağlanan işlem elemanlarından oluşan, dağıtılmış paralel bilgi işlem yapılarıdır. Yapay sinir ağlarının temel amacı; bu, insan beynindeki biyolojik sinir ağlarının yapısının bilgisayar programları ile taklit edilmesini içermektedir. Çalışmamıza dayanak ve alt yapı oluşturması amacıyla ilgili literatür çalışmamız aşağıdaki gibidir.

Sundar ve arkadaşları, ANFIS çift U borulu bir ısı değiştiricideki MWCNT/su nanoakışkanın verimliliğini ve akış taşıma birimlerinin sayısını tahmin etmişlerdir. Bu çalışmada, boru içinde borulu bir ısı değiştiricide çok sayıda nanoakışkan taşıma ünitesi içinden akan su ile karıştırılan çok duvarlı karbon nanotüpler ile ısı transfer katsayısı, Nusselt sayısı, verim ve penetrasyon deneysel olarak incelenmişlerdir. Bu çalışma, 3.500'den 12.000'e kadar Reynolds sayılarında ve %0'dan %0.3'e kadar hacim konsantrasyonlarında çalışma koşullarında gerçekleştirilmiştir. Elde edilen dört parametre Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) kullanılarak tahmin etmişlerdir. Reynolds sayısı ve parçacık hacim yükü, ısı transfer katsayısını, Nusselt sayısını, verimi ve transfer birimi sayısını aynı anda üreten veya belirleyen yapay sinir ağı analizi için girdi verileridir. $\phi = \%0,3$ ve $Re = 10005$ arttığında, Nusselt sayısı, ısı transfer katsayısı, verim ve ısı transfer ünitesi sayısı baz akışkana göre

sırasıyla %31,3, %44,17, %2,51 ve %2,76 artmakta olduğu ANFIS'in orta katmandaki farklı sayıda nöron kullanılarak uygulanması 1'den 10'a kadar sonuç verir-6 Korelasyon katsayısı ile (R^2) 0,9978 ve 0,9998 olup, ısı transfer katsayısı ve Nusselt sayısının ortalama kare hataları sırasıyla 0,0018581 ve 0,0014159'dur. Yukarıda geliştirilen çerçeve ile tüm parametrelerdeki değişikliklerin %96'sı başarıyla tahmin edilebilmektedir (Sundar vd., 2023, s. 102).

Okwu ve arkadaşları, çok kaynaklı çok hedefli sistemlerde maliyet analizi için ANFIS modeline göre, yöneticiler, özellikle ikili envanter veya çok envanterli sistemlerde, tahsis kararlarında belirsizlikle karşı karşıya kaldığını ifade etmişlerdir. Ne yazık ki pek çok araştırma, hiçbir zaman tatmin edici çözümleri garanti etmeyen, ürün dağıtım teknikleri gibi geleneksel yaklaşımlara odaklanmıştır. Gerçek dünya problemleri, deterministik olmayan polinom zamanında (NP-zor) zordur ve bunları çözmek nispeten zordur. Bu tür karmaşık problemler, verimli ve sağlam hibrit hesaplama algoritmaları gerektirmektedir. Bu çalışma, yüksek performanslı ürünlerin dağıtımı için akıllı hibrit teknolojilere duyulan ihtiyacı vurgulamaktadır. ANFIS hibrit yazılım hesaplama algoritmasını çift kaynaklı ve çok hedefli sistemlerde ürün dağıtımına uygulamışlardır. Bu kurallar mevcut girdi veri setine göre geliştirilmiştir. Ürünleri iki üretim tesisinden 15 mevcut depoya dağıtmak için yaratıcı bir algoritma kullanmak, şirketin mevcut yaklaşımıyla karşılaştırıldığında genel maliyette %13,5'lik bir azalmayla sonuçlandığı tespit edilmiştir. Sonuçlar yöntemin tatmin edici ve maliyet modellemeye uygun olduğunu göstermektedir. Üstelik kullanımı basit ve klasik yöntemlerden daha iyi performans gösterdiği sonucuna varmışlardır (Okwu vd., 2023, s. 1266-1279).

Sarr ve arkadaşları, Heliostat izleme hatasını tahmin etmek için ANFIS ve ANN modelleri, bir güneş kulesinin enerji verimliliği ve performansı, heliostatın boyutundan büyük ölçüde etkilendiğini, reflektörün doğru şekilde takip edilmesini sağlamak için genellikle yansıyan ışının konumunu değerlendirmek gerektiğini ifade etmişlerdir. Heliostatların çok sayıda olması nedeniyle bu işlem pahalı ve zaman alıcı olduğunu, izleme heliostatlarının değerlendirilmesi için daha hızlı ve daha pratik bir yöntemin geliştirilmesine de ihtiyaç olduğu belirtmişlerdir. Bu makale, heliostat arıza takibini hızlı ve doğru bir şekilde tahmin etmek için Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) ve Yapay Sinir Ağı'na (ANN) dayalı bir tahmin

modelini benimsemektedir. Model yedi farklı güne ait deneysel verilere dayanmaktadır. Giriş parametreleri saat ve tarih sayılarıdır ve çıkış, yansıyan ışının yükseklik ve azimut eksenleri boyunca konumu, bu iki tekniği kullanarak yansıyan ışık ışınlarının yerini tahmin etmek mümkün olduğunu tespit etmişlerdir. Sonuçlar karşılaştırıldığında, akıllı yöntemlerin geleneksel hataya dayalı geometrik modellerden daha iyi performans gösterdiğini göstermektedir. ANFIS modeli için 0,97'ye eşit bir korelasyon katsayısı (R^2) elde edilmiştir. YSA için ise yükseklik ve azimut eksenleri için korelasyon katsayıları (R^2) sırasıyla 0,96 ve 0,92 olduğu akıllı yöntemler, heliostat ışın konumlarını tahmin etmek için umut verici bir alternatif temsil ettiği sonucuna varmışlardır (Sarr vd., 2023, s. 2804).

Kaya ve arkadaşları çalışmalarında, yapay sinir ağı (YSA), ARIMA ve zaman serisi ayrıştırma tekniklerini kullanarak Türkiye'de otomobil satışlarını etkileyen önemli faktörleri bulmayı ve Türkiye'deki otomobil satışlarını tahmin etmeyi amaçlamışlardır. Tahmin modeli, otomobil satışlarını, otomobil fiyatlarını, euro ve dolar döviz kurlarını, istihdam oranlarını, tüketici güven endeksini, petrol fiyatlarını ve tüketici güven endeksini, sanayi üretimini, otomobil satın alma olasılığını, kadın istihdamını, genel ekonomik koşulları ve genel ekonomiyi içermektedir. Maddi duruma ilişkin beklentiler ile ailenin maddi durumuna ilişkin beklentilerinin regresyon sonuçları, ABD doları kurundaki değişimlerin, hane halkının finansal durumuna ilişkin beklentilerin, mevsimsellikten arındırılmış sanayi üretim endeksinin ve bir ay önceki logaritmik otomobil satışlarının, otomobil satışlarının anlamlı değişkenleri üzerinde anlamlı bir etkiye sahip olduğunu tespit etmişlerdir. Sonuçlar, MAPE=%1,18 ve RMSE=782 değerleriyle YSA'nın ARIMA ve zaman serisi ayrıştırma tekniklerinden daha iyi tahmin performansına sahip olduğunu sonucuna varmışlardır (Kaya ve Kaya, Çebi, 2022, s. 50-60).

Cankurt ve arkadaşları çalışmalarında, çok değişkenli tahmin için çok sayıda girdi değişkenini ele almak üzere sinir ağlarını ANFIS ile entegre ederek entegre bir model geliştirmeyi amaçlamışlardır. Önerilen yaklaşımda, iki sinir ağı modeli tipi temel öğrencinin ve yığılmış topluluklar bağlamında bir ANFIS meta öğrencisi işbirliği grubu oluşturmuşlardır. ANFIS (meta-öğrenen) ve ANN (temel öğrenen) modellerinin entegrasyonunun, bağımsız temel öğrenen modellerinden daha iyi performans gösterdiğini tespit etmişlerdir. Sayısal sonuçlar, önerilen entegre modelin

MAPE'sinin %7,26 olduğunu, tek örnekli YSA modelinin MAPE'sinin ise sırasıyla %8,50 ve %9,18 olduğunu gözlemlenmiştir. Son olarak bu çalışma, yapay sinir ağlarına dayalı bireysel uzman sistemlerden daha iyi sonuçlar gösteren, turizm talep tahmininde entegre sistemlerin yeni bir uygulamasını temsil ettiği sonucuna varmışlardır (Cankurt ve Subaşı, 2022, 3455-3467).

Chen ve arkadaşları çalışmalarında, heyelan duyarlılığını haritalamak için uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS) modelini optimize etmek için öğretim tabanlı optimizasyon (TLBO) ve Satin Bowerbird Optimizer (SBO) algoritmaları kullanmışlardır. Çalışma alanında 152 heyelan tespit etmişler ve bunları rastgele eğitim veri seti (%70) ve doğrulama veri seti (%30) olarak iki gruba ayırmışlardır. Ayrıca heyelanı etkileyen toplam 15 faktör seçilmiştir. Adım adım ağırlık oranı analizi (SWARA) yöntemi, farklı etkileyici faktörlerin göreceli önemini ve ağırlığını belirlemek için kullanmışlar son olarak, iki modelin genel performansı, ortalama kare hatası (RMSE), işlem süresi, yakınsama ve alıcı işletim karakteristikleri altındaki alan (AUROC) gibi çeşitli ölçümler kullanılarak yapılan karşılaştırmaların doğrulandığını tespit etmişlerdir. Sonuçlar, eğitim verileri kapsamındaki ANFIS, ANFIS-TLBO ve ANFIS-SBO modellerinin AUROC değerlerinin sırasıyla 0,808, 0,785 ve 0,755 olduğunu, doğrulama veri seti ile ilgili olarak ANFISSBO modelinin AUROC değeri 0,781 ile daha yüksek olurken, ANFIS-TLBO ve ANFIS modellerinin AUROC değerleri sırasıyla 0,749 ve 0,681 olarak tespit edilmiştir. Ayrıca ANFIS-SBO modelinin doğrulama veri setinde daha düşük bir RMSE değeri göstermesi SBO algoritmasının daha iyi optimizasyon yeteneklerine sahip olduğunu gözlemlenmiştir. Aynı zamanda ANFIS-SBO modelinin işlem süresi ve yakınsaması ANFIS-TLBO modeline göre çok daha yüksek olduğu dolayısıyla bu makalede önerilen iki entegre model yeterli sonuçlar sağlayabilmekte olup, mükemmel doğruluğu ve verimliliği nedeniyle çalışma alanında heyelan duyarlılığı değerlendirmesi için en uygun model olarak ANFIS-SBO modeli olduğu sonucuna varmışlardır (Chen vd., 2021, 93-107).

Sakar ve arkadaşları çalışmalarında, poliüretanla işlenmiş polyester kumaşların su emme davranışını tahmin etmek için ANFIS ve YSA modellerinin karşılaştırmışlardır. Uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS) ve yapay sinir ağı (ANN) yöntemlerini kullanarak tekstil substratlarının adsorpsiyon

özelliklerini simüle etmek için tahmine dayalı bir model geliştirmişlerdir. Bu çalışmada, tahmine dayalı bir model geliştirmek ve doğrulamak için boyalı polyester örme kumaşlara akrilik bağlayıcıyla birlikte poliüretan (PU) uygulamışlardır. Morfolojik incelemede poliüretan ve akrilik yapıştırıcılarla formüle edilen solüsyonların kumaş yüzeyine etkili bir şekilde uygulandığı tespit edilmiştir. ANFIS modeli, giriş parametreleri olarak bağlayıcı (mL) ve PU (%) dikkate alınarak, tek çıkış parametresi ise absorbans (%) dikkate alınarak oluşturulmuştur. Öte yandan sistem, YSA modelini oluşturmak için eğitim için verilerin %70'ini kullanırken, test ve doğrulama her biri verinin %15'i kullanılarak gerçekleştirmişlerdir. Ağ, Levenberg-Marquardt öğrenme algoritmasının geri yayılımı kullanılarak eğitilmiştir. ANFIS ve YSA modelleri için belirleme katsayıları (R^2) sırasıyla 0,98 ve 0,93'tür olduğu, her iki tahmin modeli de mükemmel ortalama mutlak hata oranlarına sahip (ANFIS modeli için %0,76 ve YSA modeli için %1,18) olduğu gözlemlenmiştir. Ayrıca ANFIS ve YSA modellerinin ortalama kare hatasının (RMSE) sırasıyla %0,61 ve %1,28 olduğu, geliştirilen modelin poliüretan ve akrilik yapıştırıcılarla işlem görmüş kumaşların adsorpsiyon özelliklerini tahmin etmede mükemmel performans gösterdiği tekstil endüstrisindeki deneme-yanılma çabalarını ortadan kaldırmak için tekstil malzemelerinin spesifik fonksiyonel uygulamalarına yönelik tahmine dayalı modeller geliştirmek için bir temel oluşturabilir ve sonuçta fonksiyonel tekstillerin büyük ölçekli üretimine katkıda bulunabileceği sonucuna varmışlardır (Sarkar vd., 2021, s. 7-15).

Mousazadeh ve arkadaşları çalışmalarında, ELM ve ANFIS-PSO stratejilerini kullanarak kuyu deliğine yakın yoğunlaşma viskozitesi tahmini yapmayı amaçlamışlardır. Çalışmada bu amaçla Aşırı Öğrenme Makinesi (ELM) ve Parçacık Sürü Optimizasyonu ile Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS-PSO) yöntemleri uygulanmıştır. Rezervuar sıcaklığı ve basıncı, özgül ağırlık (SG), API yoğunluğu ve gaz-petrol oranı (R^5) dahil olmak üzere kapsamlı bir rezervuar ve akışkan özellikleri verilerini kullanmışlardır. Sonuçlar, ANFIS-PSO'nun R-kare ve RMSE'sinin sırasıyla 0,762 ve 0,15 olduğunu, ELM'nin bu değerlerinin ise 0,941 ve 0,06 olduğunu gözlemlenmiş bu da ikinci modelin çıktı değeri tahmini açısından daha iyi performans gösterdiğini tespit etmişlerdir. Sonuçlar, SG'nin viskozite üzerinde en büyük etkiye sahip olduğunu ve API yerçekiminin ise en az etkiye sahip olduğunu

kondens viskozitesi hesaplaması için referans olarak uygulanabileceği ayrıca genişletilmiş veri setleri aracılığıyla ticari yazılımlarda da kullanılabileceği sonucuna varmışlardır (Mousazadeh vd., 2021, s. 2-8).

Lawal ve arkadaşları çalışmalarında, granit ocağı patlamalarının neden olduğu yer titreşimlerini tahminlemeyi amaçlamışlardır. Geliştirilen genetik ifade programlama uygulamasının, sinüs-kosinüs algoritması için optimize edilmiş ANFIS ve YSA tahminleme uygulamalarının granit ocağı kaya patlatmaları sırasında insanları ve mülkleri tehlikeye atabilecek yer titreşimleri gibi doğal çevresel etkilerini ortadan kaldıracılabileceğini tespit etmişlerdir. Çalışmalarında Genetik İfade Programlama (GEP), Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) ve Sinüs-Kosinüs Algoritması Optimize Edilmiş Yapay Sinir Ağı (SCA-ANN), beş granit ocağındaki patlamaların neden olduğu yer titreşimlerinin tahminlenmesinde uygulanabileceği önerilmektedir. Modeldeki girdi parametreleri patlama noktasından ölçüm noktasına olan mesafe (d), her bir yavaşlamanın yük ağırlığı (w), kaya yoğunluğu (q) ve geri tepme sertlik değeri Schmidt (SRH) ve parçacık hızı (PPV) ve modelin geliştirilmesinde 100 veri seti kullanılmıştır. Önerilen modelin performansı, belirleme katsayısı (R^2) ve hata analizi kullanılarak incelenmiştir. GEP, ANFIS ve SCA-ANN modellerinin elde ettiği R^2 değerleri sırasıyla 0,989, 0,997 ve 0,999 olup hataları sıfıra yakın olduğu ve modeli ampirik modelle karşılaştırdıklarında ampirik modelden üstün olduğu sonucuna varmışlardır (Lawal vd., s. 2021, 265-277).

Gonzalez ve arkadaşları çalışmalarında, güney Hindistan'ın yarı kurak bölgelerinde günlük temel buharlaşma terlemesinin modellenmesi: ANFIS ve ampirik modelleri karşılaştıran bir vaka çalışması yürütmüşlerdir. Hindistan'ın güneyindeki yarı kurak bölge için en uygun ETo tahmin modelini tanımlamak amacıyla bir çalışma yapmışlardır. Farklı meteoroloji istasyonlarından aynı döneme ait iki farklı veri seti ve ETo'yu tahmin etmeye yönelik ampirik yöntemlere ek olarak, bir ANFIS (Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi) bilgisayar modeli uygulamışlardır. ANFIS-11 modelinin en iyi tahmini sağladığını, $RMSD=0,002$, $r=0,999$ olduğunu, RITCHIE yöntemi bu bölgedeki en uygun ampirik model olduğunu ve $RMSD=0,507$ ve $r=0,851$ 'e ulaştığını ayrıca her iki veri setine ait sınıflandırma denklemleri günlük ETo tahminleri için ele alınmış her bir duruma ilişkin sonuçlar karşılaştırıldığında ampirik modelin ANFIS modelinden daha iyi

performans gösterdiği ANFIS modelinin sonuçlarının da ümit vericidir ve bir tahmin yöntemi olarak kullanılabileceği sonucuna varmışlardır (Gonzalez Subathra vd., 2021, s. 173-184).

Khan ve arkadaşları çalışmalarında, kalp hastalığı tahmini için temel özellikleri belirlemek amacıyla makine öğrenimi tekniklerini kullanarak kalp hastalığının teşhisine odaklanmışlardır. Çalışma kapsamında kullanılan makine öğrenimi tekniklerinin daha az doğru sonuç verdiğini tespit etmişlerdir. Bu nedenle tahmin doğruluğunu artırmak için, değiştirilmiş Salp Sürü Optimizasyonu (MSSO) ve Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) kullanılarak kalp hastalığı tanısına yönelik bir IoMT çerçevesi geliştirmişlerdir. Önerilen MSSO-ANFIS, arama yeteneğini geliştirmek için Levy-ıht algoritmasını kullanarak ANFIS'teki normal öğrenme süreci kademeli öğrenmeye dayalıdır ve yerel minimumlara düşmeye eğilimli olduğunu, MSSO kullanarak öğrenme parametrelerini optimize etmek ANFIS için daha iyi sonuçlar sağladığını ve ANFIS simülasyonlar ve analizler MSSA-ANFIS'in hastalık tahmininde iyi performans gösterdiğini MSSO-ANFIS tahmin modelinin diğer yöntemlere göre daha iyi doğruluğa sahip olduğunu, MSSO-ANFIS tahmin modelinin doğruluğunu 99,45 olup diğer yöntemlere göre daha yüksek olduğu sonucuna varmışlardır (Khan ve Algarni, 2020, s. 122259-122269).

İnan ve arkadaşları çalışmalarında, rüzgar hızı tahmini, gemi rotalarının belirlenmesi, rüzgar modellerinin etkin şekilde kullanılması ve tarımsal faaliyetlerin doğru planlanması gibi birçok alanda önemli bir rol oynadığını ifade etmişlerdir. Rüzgar hızı tahminlerini hesaplamak için yapay sinir ağı (YSA) ve uyarlanabilir yapay nöro-bulanık çıkarım sistemi (ANFIS) kullanmışlardır. Çalışmalarında tahmin için gerekli bilgileri POSEIDON şamandıra sisteminde yer alan E1M3A isimli şamandıradan elde etmişlerdir. YSA, 3 katmanlı, 50 nöronlu, 6 girişli ve 1 çıkışlı, harici girişli, doğrusal olmayan, otoregresif bir yapay sinir ağıdır (NARX), tanıtılan ANFIS sistemi, 6 giriş, 1 çıkış ve giriş başına 3 üyelik fonksiyonuna (MF) sahip bir bulanık çıkarım sistemi olup sistem, üç saat sonra rüzgar hızı tahminini gerçekleştirecek şekilde eğitmişlerdir. Tahmin sonuçlarına göre YSA, eğitimde 2,19 MSE ve 0,897 R, doğrulamada 2,88 MSE ve 0,866 R, testte ise 2,93 MSE ve 0,857 R değerlerini ve ANFIS yöntemiyle 0,31634 MSE ve 0,99 R değerlerinin uygun olduğu sonucuna varmışlardır (İnan ve Baba, 2020, s. 55-61).

Wong ve arkadaşları çalışmalarında, yapay sinir ağının (YSA), uyarlanabilir nöro-bulanık çıkarım sisteminin (ANFIS) ve çoklu doğrusal regresyon (MLR) modellerinin etkinliğini karşılaştırmakta ve Cu(II) giderimi için biyokömürün adsorpsiyon verimliliğini tahmin etme yeteneklerini ve temas süresi, çalışma sıcaklığı, biyokömür dozajı ve başlangıçtaki Cu(II) iyon konsantrasyonu gibi çalışma parametrelerinin Cu(II) iyonunun uzaklaştırılması üzerindeki etkilerini incelemiştir. YSA'daki 11 farklı eğitim algoritması ve ANFIS'teki 8 farklı üyelik fonksiyonu istatistiksel olarak karşılaştırıldı ve tahmin hataları yani ortalama kare hata (RMSE), ortalama mutlak hata (MAE) ve kesinlik açısından değerlendirilmiştir. YSA modelindeki gizli nöron sayısının ve ANFIS'teki bulanık kümelerin kombinasyonunun etkisi Gauss üyelik fonksiyonları ve bulanık kümelerin bir kombinasyonunu kullanan ANFIS modeli, bulanık kümelerin eğitimi ve testi için sırasıyla %90,24 ve %87,06 doğruluk oranlarıyla en iyi yöntem olduğunu tespit etmişlerdir. Sonuçlar YSA, ANFIS ve MLR modelleme teknikleri kullanılarak sulu çözeltideki Cu(II) iyonlarının rambutan kabuğu biyokömürü ile adsorpsiyonunun uygun değerler verdiği sonucuna varmışlardır (Wong vd., 2020, s. 439).

Güven ve arkadaşları çalışmalarında, yapay sinir ağı (YSA) ve destek vektör makinesi (SVM) yöntemleri kullanılarak perakende hazır giyim sektöründe renk parametrelerine olan talebin tahmin edilmesini amaçlamışlardır. Bu kapsamda yapay sinir ağları (YSA) ve destek vektör makineleri (SVM) gibi yapay zekâ modelleri oluşturulmuş ve veri setinden sonuçlar çıkarılmıştır. Model oluşturulurken dokuz farklı ürün için ürün renk detayı içeren ve içermeyen veri setleri ile tüm ürünleri kapsayan birleştirilmiş veri seti oluşturularak tahmin işlemi gerçekleştirilmiştir. Sonuçlar, yapay sinir ağlarının akromatik veri setlerinde on veri setinden yedisinde destek vektör makinelerinden daha iyi performans gösterdiği ve renkli veri setlerindeki performanslarının tutarlı olduğunu tespit etmişlerdir. Yöntemlerin sonuçları karşılaştırıldığında bu çalışmanın güvenilir olduğu sonucuna varmışlardır (Güven ve Şimşir, 2020, s. 106678).

Zanganeh, çalışmasında rüzgarla tahrik edilen dalgaları tahmin etmede uyarlanabilir ağ tabanlı bulanık çıkarım sistemi (ANFIS) modelinin eksikliklerinin üstesinden gelmek için parçacık sürüsü optimizasyonu (PSO) algoritması kullanılmasını önermektedirler. Çalışmalarında dalga tahminlenmesini ANFIS

modeliyle üç açıdan birleştirilerek bulanık çıkarma ve bulanık IF'yi optimize etmek için iki PSO algoritmasını, çıkarımlı kümeleme parametrelerini optimize etmek için PSO algoritmasını ve IF-THEN bulanık kontrol parametrelerini optimize etmek için ANFIS modelini kullanmışlardır. Kullanılan üçüncü modelin çıkarımlı kümeleme parametrelerini ve bulanık IF-THEN kural parametrelerini optimize etmek için yalnızca PSO algoritmasının Michigan Gölü'ndeki Ulusal Veri Şamandırası Merkezi (NDBC) tarafından toplanan veri setleri, önemli dalga yüksekliği ve tepe spektral periyodu dahil olmak üzere dalga parametrelerini tahmin etmek için geliştirilen en uygun model olduğu ve ANFIS modelinin doğruluğunu arttırmada PSO algoritmasının etkinliğinin yüksek olduğu sonucuna varmışlardır (Zanganeh, 2020, s. 84-99).

Kalaycı, çalışmasında, 2002-2014 yılları arasında aylık olarak derlenen veri seti ile 2015 yılı için Türkiye'de doğal gaz talebi tahmini ANFIS (Adaptive Neuro-Fuzzy Inference System) ve "Uyarlamalı Sinirsel Bulanık Denetim Sistemi" aracılığıyla tahminlemeyi amaçlamışlardır. Çalışmalarında doğal gaz tüketimini etkileyen birçok faktör olmasına rağmen üç girdi parametresi olarak gayri safi doğal üretim, sıcaklık ve nüfus verilerini kullanmışlardır. 2002-2014 yılları arasında aylık olarak derlenen bu veri seti, ANFIS'in tahmin ettiği doğal gaz tüketim verilerini gerçek doğal gaz tüketim verileriyle karşılaştırarak modelin performansını ölçmek için kullanılan MAPE'yi (ortalama mutlak yüzde hatası) hesaplanmış sonuçlar MAPE daha düşük olup, uyarlanabilir model pozitif tahminler verdiği sonucuna varmışlardır (Kalaycı, 2020, s. 495-511).

Özmen ve arkadaşları çalışmalarında, yapay sinir ağları (YSA) ve yapay bulanık sinir ağları (ANFIS) kullanılarak iris çeşitlerini sınıflandırmayı amaçlamışlardır. Yaygın olarak dağılan iris türlerinden alınan örnekleme verilerini kullanarak YSA modelinde üç katman, bir geri besleme katmanı, dört giriş ve bir çıkış modeli geliştirmişlerdir. YSA modelinin eğitimi için 90 veri örneği, test süreci için ise 60 veri örneği kullanılmış, iki modelin gerçek ve tahmin edilen değerleri karşılaştırıldığında düşük hata oranına ulaştığını tespit etmişlerdir. Sonuçlar YSA ve ANFIS yöntemlerinin sınıflandırma sonuçları karşılaştırıldığında YSA yönteminin ANFIS yöntemine göre daha doğru tahminler sağladığı sonucuna varmışlardır (Özmen ve Gülbandılar, 2019, s. 5-11).

Türk ve arkadaşları, yapmış oldukları çalışmalarında uygun üretim tahminlerini belirleyebilen yapay sinir ağı tabanlı bir simülasyon sistemi kullanılarak önceki tüm sonuçların zaman serilerinin değerlendirilmesine odaklanmaktadırlar. Üretim simülasyonlarının sonuçları, gelecekteki talebi ve bu talebi karşılamak için gereken süreyi tahmin etmek amacıyla geçmiş veriler olarak kullanılmış, zaman serisi tahmininin sonuçlarının üretim süreçlerini optimize etmek ve kullanılabilecek kalıpları çıkarmak için veri madenciliğinde kullanılabileceği bir alan olduğu sonucuna varmışlardır (Türk ve Kıanı, 2019, s. 30-37).

Şahin ve arkadaşları çalışmalarında, Avrupa futbol maçlarında katılım gereksinimlerinin tahminlenmesini için ANFIS, bulanık mantık, YSA ve yapay sinir ağı (ANN) kullanılarak Avrupa futbol maçları sırasında seyirci talebini tahmin etmek için bir model geliştirmişlerdir. En etkili yöntemin belirlenebilmesi için her yöntemi farklı koşullar altında analiz ederek 236 futbol maçından ve 2017/2018 sezonundan elde edilen verileri ile ANN ve ANFIS modelleri eğitilmiştir. Tüm modellerden elde edilen sonuçlar birbirleriyle ve gerçek geçmiş verilerle her modelin performansını değerlendirmek için ortalama mutlak yüzde hata (MAPE) ve ortalama mutlak sapma (MAD) karşılaştırıldığında YSA modellerinin diğer modellere göre daha iyi performans gösterdiğini tespit etmişlerdir. Son olarak, sonuçlar önerilen YSA modelinin tahmin amacıyla etkili bir şekilde kullanılabileceği sonucuna varmışlardır (Şahin ve Erol, 2018, s. 1-14).

Öztürk ve arkadaşları, yapmış oldukları çalışmalarında ANFIS, bulanık mantık, YSA ve yapay sinir ağı (ANN) gibi uygulamaların dünya geliştikçe bilgisayarlar ve bilgi sistemleri hayatın vazgeçilmez bir parçası haline geldiğini, ev aletlerinden cep telefonlarına kadar birçok araç bilgisayar sistemleriyle çalıştığını belirtmişlerdir. Bunun da insan beyni ile cihaz arasındaki etkileşimi kaçınılmaz hale getirdiğini, bilgisayar sistemleri ve yapay zekaya olan ilgi ve araştırmalar giderek arttığını ifade etmişlerdir. Özellikle yapay zeka ve yapay sinir ağları insansı robotlarla birlikte hız kazandığını, yapay sinir ağlarının, biyolojik sinir ağlarıyla aynı şekilde inşa edildiğini bilginin mümkün olduğu kadar doğru şekilde öğrenilmesi ve uygulanması ilkesinin esas olduğunu vurgulamışlardır (Öztürk ve Şahin, 2018, s. 25-36).

Arslankaya ve arkadaşları, çalışmalarında yapay sinir ağıları kullanılarak otomobil şirketi satışlarının zaman serisi analizi ve tahmin edilmesi hakkındaki çalışmasında, otomobil sektörü artık gelişmiş ve gelişmekte olan ülkelerde kilit bir sektör haline geldiğini belirtmektedir. Sakarya’da faaliyet gösteren Türkiye’nin önde gelen otomobil üreticilerinden bir firmada, gelecek yıllardaki araç satışlarını belirlemek için zaman serisi analizleri, nedensel yöntemler ve yapay sinir ağıları uygulamaları kullanılmıştır. Bu yöntemlerin karşılaştırılması yoluyla firma için en iyi tahmini sağlayan yapay sinir ağıları olduğu ve bu yöntemle yapılan tahminler dikkate alındığında şirketin yıllık bütçesinin ve genel üretim planının sağlam bir temele oturtulması gerektiğini tespit etmişlerdir. Bu yaklaşımı kullanarak şirket, satış rakamlarını önceden tahmin ederek bazı otomotiv politikalarını ve üretim planlarını daha iyi tahmin edilebileceği sonucuna varmışlardır (Arslankaya ve Öz, 2018, s. 1482-1492).

Doğan, yapmış oldukları çalışmada, Uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS) kullanarak talep tahmini ve uygulaması hakkındaki çalışmasında, günümüzde rekabet faktörlerinin hızla artması, kuruluşların karar verme sorunlarıyla karşılaştıklarında rasyonel davranmaları gerektiği anlamına geldiğini belirtmektedir. Bu çalışma, kurumsal talep tahmininin bu kritik sorununa çözüm bulmak için ANFIS’i uygulamaları ile önerilen model için öncelikle talebi etkileyen faktörler belirlenmekte ve bu faktörlere ilişkin veriler kullanılarak bir model veri tabanı oluşturulmuştur. ANFIS yönteminin talep modeli tahmini için yararlı olduğu sonucuna varmışlardır (Doğan, 2016, s. 257-288).

Gökçe ve arkadaşları, ANFIS ve YSA yöntemleri kullanılarak doğal taş üretim süreçlerinin işlenmesinde verimlilik analizi, çalışmasında doğal taş üretimi yapan firmalara taş şeklinde giren ham levhaların boyutsal analizi yapmayı amaçlamışlardır. Şirket üretiminin doğasını yansıtan periyodik ilişkiler veri tabanı geliştirilerek şirket yöneticilerine üretimin planlanması ve kontrolünde yardımcı olabilecek bir yardımcı sistem oluşturulmuştur. Ayrıca oluşturulan veri tabanındaki bilgiler, yapay sinir ağıları ve ANFIS kullanılarak blokların verimliliğini ve üretim süresini tahmin etmek için iki farklı model geliştirilerek uygulanmıştır. Modelleme ve veri girişi süreci tamamlandıktan sonra verimlilik tahminleri üretilmiş araştırma

sonucunda hata oranı en yüksek yapay sinir ağı modelinin %4,9'a ulaşarak yeterli sonuçlara ulaştığı sonucuna varmışlardır (Gökçe ve Sonugür, 2016, s. 174-185).

Candan ve arkadaşları, ilaç endüstrisinde yapay zeka kullanarak talep tahmini hakkındaki çalışmasında, nörofuzzy yöntemleri kullanarak dış faktörlerin etkisini dikkate alarak geçmiş satışlara dayanarak gelecekteki talebi ANFIS, yapay sinir ağı (YSA) topolojisinde dış etkilerin bozulması nedeniyle nöro-bulanık bir yöntem olarak kullanılan modelin verilen uygulama yönteminin etkinliğinin yüksek olduğu sonucuna varmışlardır (Candan vd., 2014, s. 41-49).



2. ÜRETİM VE ÜRETİM YÖNETİMİ

Üretim, insan ihtiyaçları için belirli girdileri farklı işlemler uygulayarak mal ve hizmet biçiminde çıktılar elde etmektir.

2.1. Üretim ve Üretim Yönetiminin Tanımı

Günümüz teknolojik gelişmeleri firmaların üretim faaliyetleri üzerinde özel bir etkiye sahiptir. Bir şirketin küresel rekabette başarılı olabilmesi, bu gelişmeleri takip etmesine ve uygulamasına bağlıdır. Üretim ve teknoloji birbirinden bağımsız düşünülmemektedir. Üretim, doğal kaynakları insan ihtiyaçlarını en iyi şekilde karşılayan mal ve hizmetlere dönüştüren fiziksel, kimyasal ve mekanik süreçler bütünü olarak tanımlanabilir (Eroğlu ve Tatar, 2023, s. 401-411).

Üretim yönetimi, üretim faaliyetlerinin planlanması, koordinasyonu ve yürütülmesini içerir. Üretim yönetiminin amacı, kaynakların kullanımını optimize etmek, kayıpları en aza indirirken verimli çalışmak ve kaliteyi istenilen düzeye çıkarmaktır. Diğer bir ifadeyle üretim yönetimi, istenilen kalite ve standartta mal ve hizmetlerin istenilen zamanda ve en düşük maliyetle elde edilmesi için gerekli kararları içeren bir işletme fonksiyonudur. Diğer bir deyişle üretim yönetimi, nicelik, kalite, zaman ve maliyet parametrelerini optimize etmeyi amaçlayan bir kavramdır (Kuşcuoğlu ve Dilik, 2023, s. 80-89).

2.2. Üretim Sistemleri Tasarım ve İşleyişi

Üretim sistemi, makine, ekipman, malzeme, enerji, işçilik ve zaman gibi girdilerin mal ve hizmet şeklinde çıktılarına dönüştürüldüğü ve sonuçların geri bildirim yoluyla gösterildiği süreçtir. Üretim sistemi, işletmenin iç ve dış çevresi ile etkileşim içindedir. Üretim sistemi, ekonomi, hükümet düzenlemeleri, rekabet, teknoloji ve diğer dış çevre koşullarının olumlu ve olumsuz etkileri vardır. Üretim, pazarlama, finans, muhasebe, insan kaynakları, yönetim bilgi sistemleri ve mühendislik gibi diğer işlevlerle çok yakın ilişkilere ve etkileşimlere sahiptir.

Ancak diğer fonksiyonlardan farklı olarak üretim yönetimi bir şirketin varlıklarının yaklaşık %80'inden ve insan kaynaklarının %60-80'inden sorumludur (Şahan ve Altınbay, 2023, s. 21-39).

Bir üretim sisteminin temel unsuru dönüşüm sürecidir. Üretim yönetimi, girdilerin şirketin hedef pazarına uygun çıktılara dönüştürülmesinden sorumludur. Bu, herhangi bir organizasyonun temel işlevlerinden biridir. Üretim yönetimi kavramları; üretim stratejisi, süreç tasarımı, envanter kontrolü, üretim planlama ve çizelgeleme gibi birçok alt konuyu içerir. Dönüşüm sırasında, girdiler, şekil değişiklikleri, nakliye, depolama ve inceleme gibi birçok faaliyet, sonunda başlangıçtaki durumundan daha yüksek değere dönüştürülür. Bir hizmet üretme süreci, bir mal üretme sürecinden çok farklıdır. Hizmetler, mallardan daha soyuttur, yüksek tüketici katılımını gerektirir, üretim sırasında tüketilir, depolanamaz, benzersiz kalite özelliklerine sahiptir ve emek yoğunudur (Apak, 2022, s. 62-74).

2.3. Üretim Yönetiminin Amaçları

Giderek artan rekabet ortamında hızlı yanıt, dakiklik, düşük maliyet ve yüksek verimlilik sağlamak için üretim planlaması üretim yönetiminin en önemli adımlarından biridir. Üretim planlaması, üretim faaliyetinin gelecekteki seviyelerini ve sınırlarını belirlemek için kullanılır. İyi bir üretim yönetim sistemi ile işletmeler, tedarik zincirinin hareketini düzgün bir şekilde yönetebildikleri için fabrika yapımı ürünleri vaat edilen zaman çerçevesi içinde üretebilirler. Gereksiz faaliyetleri azaltma çabaları, verimli faaliyetin önemini artırırken, zamanında ürün teslimi bilgi doğruluğunu artırır ve kurumsal kaynak planlama (ERP) ve üretim kaynak planlama sistemleri (MRP), planlama ve üretim süreçlerinin kalitesini artırır (Aydın ve Dursun, 2022, s. 9-23).

2.4. Stok Maliyeti ve Yönetimi

İşletmelerin üretim sürecinde hammadde ve yardımcı maddelere ihtiyaç duyulmaktadır. Bu nedenle stok kontrolü, üretim planlaması ile yakından ilgilidir. Gelecekteki üretim ihtiyaçlarının karşılanabilmesi için stok seviyelerinin, işletmenin

retim, satıř ve finansal durumu dikkate alınarak ekonomik olarak belirlenmesi gerekmektedir. Envanter kontrol bu faktrleri deęerlendirir ve optimum depolama maliyetlerini dengeler. Envanter kontrol eřitli yntemler kullanılarak gerekleřtirilebilir. Bilgisayarlar bu kontrollerin saęlanması da önemli bir rol oynamaktadır. Envanter kontrol ařamasında yer alan bilgi iřlem yk, insan kaynaklarını ařar ve bilgisayar kullanımını gerektirir. Her rn iin tanımlanan kodlar sayesinde tm bilgiler saklanmakta ve gerektięinde otomatik olarak hesaplanabilmektedir (Kurtlar ve Atıř, 2022, s. 173-192).

2.4.1. Envanter Ynetimi

retim ynetimi ve stok ynetimi yakından iliřkili ve ayrılmaz kavramlardır. Paylařılan; bir sre atıl duran, kullanılmayı ve satılmayı bekleyen, ekonomik deęeri olan mal ve malzemelerdir. Stok ynetiminin en önemli grevleri, retim ve depolama miktarlarını planlamak, kontrol etmek ve sorunları ortadan kaldırmaktır. Faydalar ve maliyetler arasındaki farkı en st dzeye ıkaran sipariř veya retim miktarlarını belirleyin ve řirketin vergi ykmllęn en aza indiren envanter deęerlemeleri gerekleřtirilir. řirket, geleceęe ynelik belirsizlikleri ortadan kaldırmak iin stok ynetimine byk nem vermektedir. Bir iřletmede stok ynetimi ayrı bir departman olabileceęi gibi, retim planlama, kontrol veya retim departmanlarından birinde de yer alabilmektedir (Sarıkaya vd., 2022, s. 413-439).

2.4.2. Envanter Ynetiminin nemi

Stok ynetimi, řirketin satın alma ve satıř maliyetlerini azaltır ve maddi kayıpların nne gemektedir. Aynı zamanda yeni makineler, retim planlamasındaki insan ve malzeme lsnn koordinasyonuna yardımcı olarak trafik sıkıřıklıęını ve gereksiz duraklamaları azaltmaktadır. Envanter planlama ve kontrol, yalnızca iř liderlerinin nceden plan yapmasına ve riski azaltmasına yardımcı olabilir. En iyi envanter ynetim sistemi, iř hedeflerine dayalı olarak talebi karřılamak iin envanteri dengede tutan sistemdir. Envanter, retim sistemi tarafından retilen rnlerin retimine doęrudan veya dolaylı olarak katılan tm fiziksel malların miktarı veya parasal deęeri ile llr. Envanter seviyeleri, belirli

sektörlerde varlıkların ve işletme sermayesinin önemli bir bileşenidir. Dolayısıyla işletmeler için önemlidir. Stok yönetiminin en önemli görevleri, üretim ve depolama miktarlarını planlamak, kontrol etmek ve sorunları ortadan kaldırmaktır (Yerlikaya ve Arıkan, 2022, s. 1703-1712).

2.4.3. Envanter Yönetiminde Etkinlik İlkeleri

Envanter yönetimi, firmaların rekabet önceliklerini karşılamak için uygulanan planlanma ve kontrolüdür. Etkili envanter yönetimi, herhangi bir tedarik zincirinin tam verimliliği için kritik öneme sahiptir. Buradaki zorluk, maliyetleri azaltmak için envanteri azaltmak veya tüm talebi karşılamak için fazla stok yapmak değildir; Bir işletmenin rekabet önceliklerini en verimli şekilde karşılamasını sağlayan doğru hacimlere sahip olmaktır. Envanter yönetimi, bir işletmedeki mal akışını sürekli bir sipariş verme, depolama, üretim, satış ve yenileme döngüsünde düzenleme sürecidir. Envanter yönetimi genellikle iki düzeyde yapılmaktadır. Küresel envanter yönetimi, depolama yerleri ve ürün düzeyinde envanter yönetimidir. Bir envanter stratejisi belirlerken, bir şirket envanterle ilişkili sermaye miktarını en aza indirmeyi veya müşteri hizmetlerini veya üretim verimliliğini en üst düzeye çıkarmak için daha fazla envanter tutmayı seçmektedir. Stoklar temel olarak üç kategoriye ayrılır: hammaddeler/parçalar, devam eden işler ve bitmiş ürünlerdir (Can, 2021, s. 80-92).

Üretim şirketleri, hammadde veya bileşen satın alır, üretime hazır olana kadar depolar ve ardından bunları bitmiş ürünlere dönüştürür. Toptancılar ve perakendeciler gibi imalat dışı işletmeler, son kullanıcılara satmak için mamul malları depolamaktadır. Envanter bir şirketin nakdini tükettiğinden ve nakliye masraflarına neden olduğundan, tüm işletmelerin envanter ve talebi dengelemesi gerekmektedir. İşletme türü ne olursa olsun, şirketlerin üretim planlarını veya öngörülen müşteri talebini ve gerçek siparişleri karşılamak için yeterli envanter olduğundan emin olurken, paradan tasarruf etmek için envanteri sıkı bir şekilde kontrol etmesi gerekmektedir (Ağraş ve İnanoğlu, 2022, s. 697-716).

Envanter stratejisi, güvenli stok gibi ilkelere dayalı olarak envanteri madde düzeyinde yönetmeyi ve ABC sıralaması gibi stratejiler yoluyla yeniden sipariş oranlarına öncelik vermeyi ve envanter değeri, tüketim, parti büyüklüğü ve sipariş

bekleme süresi gibi madde düzeyinde özellikleri dikkate almayı içermektedir. Envanter ve fırsat maliyetlerinde önemli artışlara neden olan envanter birikimini önlemektir. Likidite ve/veya depolama sorunları durumunda envanteri en aza indirmektir (Dulkadir, 2021, s. 193-209).

Envanteri zamanında tutmak ve malzeme eksikliklerinden kaynaklanan olası kayıpları önlemek içindir. Mal ve maddeler yakından izlenmeli ve hırsızlıktan kaynaklanan kayıp veya hasarı azaltmak ve etkinliklerini artırmak için adımlar atılabilir. Satışların yılın belirli dönemlerinde veya belirli aylarda yoğunlaşması çok önemlidir. İadeleri ve müşterilerle olası anlaşmazlıkları azaltmak için kalite kontrole özel dikkat gösterilmelidir. Öngörülen üretime paralel olarak gelişen ve şirketin üretim sürecindeki dalgalanmalara uyum sağlayan bir hammadde akış politikasının izlenmesi söz konusudur. Geleceğin doğru tahmin edilmesi, artan talebin düşük fiyatlarla karşılanabilmesi için artan hammadde fiyatlarının zamanında dikkate alınmasını içermektedir (Eyitmiş ve Bilginer, 2021, s. 1204-1217).

Ağır stok mallardan kurtularak stok taşıma maliyetlerini azaltarak nakit akışını artırmaktır. Gerekirse bilgisayar ve iş araştırmasına dayalı uygun envanter kontrol yöntemleri kullanılmalıdır. Tedarik edilen bitmiş ürünlerin kalitesinin doğrulanması, sürekli kontrol yoluyla ticari kar ve ciro arasındaki ilişkinin değerlendirilmesidir. Envanter ve envanter kontrol fonksiyonlarının faydaları düzenli olarak değerlendirilmelidir. Bu sayede sorunlar zamanında tespit edilerek düzeltici önlemler alınabilir. Düşük kontrol alanları envanteri sınırlamalıdır. Satın alma, üretim ve satış alanlarında tedarik süreleri minimumda tutulmalıdır. Hammadde girişi ile üretimin tamamlanması arasında geçen süre kontrol edilmeli ve üretim temin süresinin yeterliliği değerlendirilmelidir. Gerekirse teknik mühendislik ve imalat faaliyetlerini hızlandıracak önlemler de alınmalıdır. Farklı envanter kalemleri arasında bir denge sağlanarak fazla stok azaltılmalıdır (Savsar ve Çiçek, 2021, s. 377-386).

2.4.4. Stok Çeşitleri

Stok yönetimini kolaylaştırmak ve envanter yönetimi etkinliğini artırmak için envanter belirli standartlara göre sınıflandırılır. En yaygın sınıflandırma amaca

göredir. Depolama sistemleri ile üretim sistemleri arasında çok yakın bir ilişki vardır. Stoklamak; müşteri hizmetlerini, kaynak ve ekipman kullanımını, iş gücü kapasitesini ve üretkenliği etkiler. Öte yandan imalat sanayi için malzeme temini ve envanter planlaması son derece önemlidir. Depolama sistemlerinin ulaşmaya çalıştığı nihai hedef, dengeli bir satış-üretim-depolama sistemidir. Denge, üretimi kesintiye uğratmayan stok miktarı ile o stoğun maliyeti arasındaki dengedir. Bir envanter yöneticisinin amacı, toplam maliyetleri en aza indirmektir (Yıldız, 2021, s. 157-171).

- Hammadde stokları: Hammaddenin dışarıdan temin edilerek doğrudan üretimde kullanılması suretiyle nihai ürünün elde edildiği malzemelerdir.
- Ürün Envanteri: Üretiminin tüm aşamalarını tamamlamış ürünleri ifade eder. Bu ürünler; toptancılara, perakendecilere veya diğer mağazalara gönderilmek üzere stokta bulunurlar.
- Devam Eden Envanter: Üretim envanteri, tesis sisteminde işlenmekte olan veya işlenmeyi bekleyen her tür malzeme, parça veya montajdan oluşur.
- İşletim ekipmanı: ekipman, yedek parça, temizlik ekipmanı ve kırtasiye bakım ve onarımıdır. Bu malzemeler doğrudan üretimde kullanılmaz (Yüce ve Kabak, 2021, s. 47-60).

2.5. Üretim Planlama

Üretim planlaması, müşteri ihtiyaçlarını karşılamak ve üretim ortamındaki makine, ekipman ve işgücü gibi kaynakları kuruluşun performans hedeflerine uygun olarak kullanmak için üretim faaliyetlerinin organizasyonudur. Üretim planlaması, bir üretim tesisinde önemli bir iş sürecidir. Üretim planlamasının amacı, hangi malzemeye, ne zaman, ne kadar malzemeye ihtiyaç duyulduğu sorusuna mamul, yarı mamul ve hammadde bazında cevap vermektir. Üretim planı 3 bölümden oluşmaktadır (Erozan ve Müminoğlu, 2020, s. 251-266).

- Ana üretim planı
- Malzeme ihtiyaç planlaması
- Kapasite İhtiyaç Planlaması

2.5.1. Ana Üretim Programı

Ana Üretim Programı (MPS), tüm nihai ürünler için üretim programını ana hatlarıyla belirtir; her bir ürünün beklenen miktarını ve ne zaman gerekli olacağını gösterir. Nihai ürün üretim miktarları, nihai ürün tahminleri ve müşteri siparişleri ile belirlenmektedir. MPS genellikle zamana dayalı gereksinimler cinsinden ifade edilir. Bu nedenle, planlama ufku bir haftalık birkaç planlama döneminden oluşur. Talep için bir dönem belirtmek, genellikle talep edilen miktarın dönem başında mevcut olması gerektiğini belirtmektedir. Planlama aralığının uzunluğu iş ihtiyaçlarına göre değişmektedir. Bununla birlikte, asgari planlama dönemi, nihai ürünü oluşturan birleştirilmiş tüm parçaların kümülatif tedarik süresini ve üretim süresini kapsayacak kadar uzun olmaktadır. MPS'nin bir teknoloji veya kontrol sistemi olmadığı anlaşılmalıdır. Buna karşılık MPS, karar bilgilerinin mantıksal bir temsildir. Düzgün tasarlanmış bir MPS, yönetimin başarmak istediğini başarmanın anahtarıdır (Erol ve Eken, 2020, s. 63-69).

2.5.2. Malzeme İhtiyaç Planlaması

Bir MRP sisteminin anlaşılması oldukça kolay olsa da, büyük miktarlarda malzeme veya ürünle uğraşırken bilgisayar kullanımı kaçınılmazdır. MRP, çok düzeyli üretim planlama problemleri için en yaygın kullanılan tasarım yöntemi ve simülasyon aracıdır. MRP, temel olarak bir şirketin üretimde kullandığı hammaddelerin, malzemelerin ve yarı mamullerin, ürünlerin müşterilere teslim tarihlerini, sipariş ve envanter yönetimi yönergelerini ve diğer üretim hedeflerini ve ayrıca depolamayı optimize etmeyi dikkate alarak periyodik olarak planlanmasıdır (Ersöz vd., 2020, s. 801-826).

MRP yönteminin dayandığı ilke, bağımsız gereksinimlere sahip bitmiş bir ürünle başlamak ve gerektiğinde gerekli parça ve malzemeleri hazır bulundurmaktır. Bu yaklaşım, depodaki kalemler için bekleme süresini önemli ölçüde azaltır ve böylece ilgili depolama maliyetlerini de azaltmaktadır. MRP yönetiminin başarılı bir şekilde uygulanması için iki faktör önemlidir. Birincisi, tedarik kaynaklarının güvenilir ve zamanında işletilmesidir. Çok düşük gecikmelerle, arzdaki en ufak bir aksama tüm üretimi durdurabilir. İkinci faktör, donanım gereksinim planlaması için

gereken yüksek bilgi işlem gücüdür. MRP'nin felsefesi, malzemelerin üretim programlarını aksatmayacak veya bekleme süreleri oluşturmayacak şekilde tedarik edilmesi ve malzemelerin üretim programlarını bekleyecek şekilde depolanmamasıdır (Öncül ve Ateş, 2020, s. 116-132).

2.5.2.1. Malzeme İhtiyaç Planlaması Girdileri

Bir MRP sistemi, üretim planlamasını üretimi tamamlamak için gereken malzeme listesiyle birleştirir ve hangi kalemlerin ve ham maddelerin sipariş edilmesi gerektiğini belirlemek için üretim envanterini kontrol etmektedir. Bir ürün için bir üretim planı yapıldığında, gerekli tedarik süreleri dikkate alınarak, söz konusu nihai ürün için bileşen stokunun yenilenmesi için siparişler verilir, böylece malzeme ve parçalar gerektiğinde iş istasyonlarında bulunmaktadır (Yiğit ve Aslan, 2020, s. 1721-1734).

İdeal olarak, sipariş edilen malzemeler şantiyeye tam olarak işin gerektirdiği zamanda ulaşmalıdır. Bu, envanteri en aza indirmektedir. Ancak ideal duruma ulaşmak neredeyse imkânsız olduğu için sistem, üretim planını sürekli veya periyodik olarak kontrol ederek prosedürdeki kesintileri ve düzensizlikleri en kısa sürede tespit edilmektedir. Bir MRP sistemi bu üç temel unsur olmadan çalışamaz. Bu nedenle MRP sistemi kullanmak isteyen firmaların öncelikle bu üç girdiyi sağlamaları gerekmektedir. Bir MRP sistemi bu temel girdiler olmadan çalışamaz. Bu nedenle MRP sistemi kullanmak isteyen firmaların öncelikle bu üç girdiyi sağlamaları gerekmektedir (Özkan ve Bulut, 2020, s. 1199-1212). Bir MRP sisteminin üç temel girdisi vardır.

- Ana üretim planı,
- Ürün ağacı bilgisi,
- Stok ayıt bilgileri,

2.5.2.2. Malzeme İhtiyaç Planlaması Çıktıları

MRP sisteminin çıktısı, kullanıcının ihtiyaç ve isteklerine göre işlenir. Bir MRP sisteminin en önemli çıktıları üretim ve stok kontrol raporlarıdır. Raporlama

tercih edilmekte ve ynetime plan ve program yapma imknı saęlamaktadır. MRP sisteminin ıktısı, kullanıcıların ihtiya ve isteklerine gre iřlenmektedir. MRP sisteminin ıktı raporları ok eřitli olup, firmanın zelliklerine ve kullanıcıların isteklerine gre deęiřkenlik gstermektedir. İyi tasarlanmış ve kurulmuş bir MRP sisteminin ana ıktıları řunlardır:

- Sipariř ama raporu,
- Sipariř ncelięi raporu,
- Kapasite talep raporu,
- Performans izleme raporudur (Alp ve Nayir, 2019, s. 41-57).

2.5.3. Kapasite İhtiya Planlaması

Kapasite planlaması, bir řirketin retim faaliyetlerini yrtmek iin gerekli olan insan, mekanik ve malzeme kaynaklarının belirlenmesi srecidir. Kapasite planlama, kapasiteyi ler ve retim talebini karřılamak iin kapasite seviyelerini ayarlar. Kapasite, řirketin mevcut rn grupları iin ortak bir birim olarak ifade edilmelidir (Savcı, 2019, s. 290-309).

Kapasite gereksinimleri planlaması, kısa ve orta vadeli planlama alanı iinde malzeme programını uygulamak iin gereken belirli insan gc ve makine miktarlarını belirlemektedir. Daha sonra gerekli kapasite, ařırı veya dřk yk belirlemek iin mevcut kapasite ile karřılařtırılır. Kapasite kontrol, performansın izlenmesi, kapasite planları ile karřılařtırılması, deęiřikliklerin nceden belirlenmiř limitleri ařıp ařmadıęının belirlenmesi ve dzeltici nlemlerin alınmasının saęlanması sreci olarak tanımlanabilir.

Kapasite ynetimi kendi bnyesinde planlama srecinin her ařamasında retim planının kapasiteye uygunluęunu kontrol etmekte; bu, kritik hataları tahmin etmeyi ve bunlardan kaınmayı mmkn kılmaktadır (Koruca ve Kocaer 2019, s. 897-905).

2.6. retim Kaynakları Planlaması

retim kaynak planlaması, bir reticinin kaynaklarının kullanımını verimli bir řekilde planlamak iin bir sistemdir. reticilerin gelecek iin doęru retim

planları oluřturmasını saęlayarak maliyetleri en aza indirmektedir. Maliyetler, niteliklerine gre farklı řekillerde sınıflandırılabilir. En popler yollardan biri, sabit ve deęiřken maliyetlere ayırmaktır. Sabit maliyetler artan/azalan retim birimleriyle deęiřmezken, deęiřken maliyetler yalnızca ilgilidir ve mevcut kaynakların kullanımını en st dzeye ıkarmaktadır. Malzeme ihtiya planlama bilgi sistemi, satıř tahminini gerekleřtirmek iin gerekli olan makine ve iřgc birimlerinin varsayımlarını dikkate alarak hammadde arzını ve miktarını planlamak iin kullanılan bir satıř tahmin sistemidir (Kahraman, 2021, s. 415-426).

MRP sistemleri yalnızca malzemelerin retim/sre kontrol ynleriyle ilgilenir. Kapasite gereksinimlerinin hesaplanması yoktur. retim kaynak planlaması, artan talebi karřılamak iin gereken gvenlik stoęuna, planlı ikmal teslim sresi zerinden ortalama kullanımı ekleyerek optimum hammadde miktarlarına ve sipariř sıklıklarına ulařır. retim kaynak planlaması terimi, malların retiminde yer alan řirketler tarafından kullanılan bilgi sistemlerini ifade eder. Entegre bir bilgi sistemi, retim sreci bilgilerini merkezileřtirerek, entegre ederek ve iřleyerek ynetimin karar verme srecini basitleřtirir (Haskse, 2020, s. 179-195).

2.7. İř İstasyonlarının Dzenlenmesi ve Bakımı

Bir iřletmenin retim tesislerinin yerinin belirlenmesi, retim yolları ve rn kategorileri bazında ticaret merkezi organizasyonu gibi hususlar denetim kapsamındadır. Ama, iřgc, zaman, retim kaynakları ve malzemeleri mmkn olan en verimli řekilde kullanmaktır. retim sreklilięini saęlamak ve verimlilięi artırmak iin bakım gereklidir. Bu alıřmalar her imalat firmasının temel faaliyet alanıdır. Temel ama, tm retim girdilerinin iřlevlerini yerine getirmek ve yatırımların verimlilięini artırmaktır. Bu bakım maliyetleri, toplam maliyetlerin artan bir payı ve nemidir. retim proseslerinin artan mekanizasyonu, otomasyonun artan nemi, ekipmanların operasyonel kullanılabilirlięinin srdrlmesi ve retim sreklilięi bakım faaliyetlerini daha karmařık ve nemli hale getirmektedir (Bykarıkan, 2021, s. 589-610).

2.8. Kalite Kontrolü

Kalite; amaçlanan faydasını maksimize eden bir ürün, malzeme veya hizmetin anlamı olarak tanımlanabilir. Başka bir deyişle: Kalite, müşteri odaklıdır. Bir ürün veya hizmetin kalitesi ancak müşteriye iletilmesi, ürün veya hizmetin müşterinin istek ve beklentilerini karşılaması ile mümkündür. Ürünlerin kalitesi ve güvenliği üreticiler için büyük önem taşımaktadır. Şirketler kalite veya güvenlik sorunlarıyla uğraşırken, kusurlu veya şüpheli ürünler için üretim sürecini izlemek için bir araca ihtiyaç duymaktadırlar. Üretim yönetim sistemi çözümleri, üretim sürecindeki tüm ürün izleri hakkında bilgi toplamaktadır (Karakoç ve Dardanoğlu, 2020, s. 39-56).

Satıcı, kusurlu ürünü müşteriden teslim aldıktan sonra, kusurun nedenini belirlemek için üretim izlerini yakından takip etmelidir. Bu izleri takip edebilmek için ürünün parti numarası, seri numarası ve sürüm, revizyon gibi diğer ürün bilgilerine ihtiyaç bulunmaktadır. İş dünyasında, ürünleri etkileyen önemli bilgilerin elde edilmesi genellikle zor, pahalı ve zaman alıcıdır (Başak vd., 2019, s. 157-172).

Üretim yönetim sistemi, şirketlerin ürün üretimi sırasında bilgi toplayıp depoladığı bu boşluğu dolduran bir köprüdür. Kalite yönetimi, şirkete giren ve çıkan malzemelerin izlenmesini ve belirlenmiş standartlara göre gerekli önlemlerin uygulanmasını içermektedir. Sipariş girişinden siparişin yerine getirilmesine kadar olan akışı yönetmek için kontrol mekanizmalarının kullanılması, işletmenin hayatta kalmasını garanti etmek için üretim yönetimi ve müşteri ilişkilerinin sağlıklı bir şekilde sürdürülmesini sağlamaktadır (Yücel, 2020, s. 11-19).

3. TALEP TAHMİNLEMESİ

Talep tahmini, gelecekte talep edilecek mal ve hizmet miktarını tahmin etmektedir.

3.1. Talep Tahmini Kavramı

Mal ve hizmetlere yönelik gelecekteki talebin tahmini, tüm işletme tahminlerinin başlangıç noktasıdır ve diğer işlevler için temel veriler sağlamaktadır (Şahin ve Eren, 2022, s. 191-216).

Müşteri talebini tahmin etmek, işletme yöneticilerinin stratejik kararlar almalarına, üretime konulan hammadde, işçilik ve diğer ürün miktarlarını planlamalarına ve tutulacak envanter miktarını belirlemelerine yardımcı olmaktadır (Terzioğlu ve Şahin, 2022, s. 584-596).

Talep Tahmini; Sınıflandırma, zaman aralığı, kullanım amacı, ürün tipi, bilgi işlem teknolojisi gibi çeşitli kriterlere dayanmaktadır. En sık kullanılan sınıflandırma kriteri zaman aralığıdır. Zaman aralığı kriterlerine göre sınıflandırılan talep tahmin türleri şu şekildedir (Calapoğlu vd., 2021, s. 341-357);

- Çok kısa vadeli tahmin: Haftalık veya günlük olabilir. Bu, parçaların, malzemelerin ve devam eden işlerin envanterini kontrol etmek veya montaj hatları için iş çizelgeleri oluşturmak için yapılmaktadır.
- Kısa vadeli tahmin: Genel süre 3 ila 6 aydır. En uygun üretim parti miktarını, temin süresini ve sipariş miktarını belirlemek için kullanılmaktadır. Ayrıca makineleri yüklemek ve işçilik gereksinimlerini belirlemek için kullanılır.
- Orta vadeli tahmin: 6 aydan 5 yıla kadar sürebilir. Bu, belirsiz veya uzun tedarik süreleri olan malzemelerin satın alınmasını, karmaşık üretim görevleri için üretim süreçlerinin planlanmasını ve talebin mevsimsel olarak dalgalandığı ürünlerin stoklanmasını içermektedir.
- Uzun vadeli tahmin: Süre en az 5 yıldır. Bu, ticari tesislerin genişletilmesi veya yeni makine alımı gibi konularda olmaktadır.

3.2. Talep Tahmin Prensipleri

Yüksek hacimli veya heterojen popülasyonlar için daha hassas talep tahminidir. Tahminin kapsadığı zaman aralığı ne kadar kısa olursa hassasiyet o kadar yüksek olmaktadır. Herhangi bir talep tahmini çalışması, varyansları belirlemek için hata hesaplamaları içermelidir. Talep tahmini çalışmalarının sonuçları uygulanmadan önce kullanılan talep tahmini yönteminin geçerliliği test edilmektedir (Dedeoğlu ve Çetin, 2021, s. 25-38).

3.3. Talep Tahmin Aşamaları

Talep tahminindeki adımlar şu şekildedir:

- Talep tahmininin hedeflerini belirlenmesi: Hangi tahmin yönteminin etkin bir şekilde kullanılabilmesi için talep tahmininin ne zaman kullanılacağı, gerekli doğruluk derecesi ve gerekli detay düzeyi gibi faktörlerin belirlenmesi gerekmektedir (Konuk vd., 2021, s. 97-106).
- Tahmin döneminin belirlenmesi: Talep araştırması elde edilen sonuçların kullanım maksadı ve zamanı arasında yakından bir ilişki bulunmaktadır.
- Veri toplama: Bu tahmin çalışmalarının geçerliliğini etkileyen çok önemli bir adımdır. Yararlı bilgilerin toplanması, şirketin kayıt sistemine bağlıdır. Geçmiş satışlar, tedarikler, teslimat süreleri ve işlem maliyetleri kayıtları olmadan geleceği tahmin etmek zordur (Ülker, 2021, s. 584-594).
- Tahmin yöntemi seçimi: Talep tahmini, çevresel ve içsel faktörlere bağlı çok karmaşık bir problemdir. Tahmini kolaylaştırmak için çeşitli yöntemler geliştirilmiştir. Bu yöntemler nitel yöntemler ve nicel yöntemler olarak iki gruba ayrılmaktadır (Acun ve Apalı, 2020, s. 235-244).
- Tahmini uygulamak ve sonucun geçerliliğini doğrulamak: Tahminler gerçek değerlerle karşılaştırılmalı ve farklılıkları sistematik olarak kontrol edilmelidir. Tahmine dayalı modeller, varsayımların ve verilerin geçerliliğini hedeflemelidir (Altın, ve Çelik Eroğlu, 2020, s. 540-562).

3.4. Talep Tahmin Yöntemleri

Son zamanlarda talep tahmini arařtırmalarında karmařık problemlerin çözüümü için yapay zekâ tabanlı yöntemler kullanılmaya başlanmıřtır. Literatürde yöntemleri farklı sınıflandırılrsa da temelde iki grupta ele alınmaktadır (Karabacak ve Uzundumlu, 2020, s. 561-573).

Nicel yöntemlerin girdisi, farklı zaman aralıklarında toplanan verilerdir. İyi veri analizi bu yöntemlerin temelini oluşturmaktadır. Nitel yöntemler ise, konu uzmanlarının bilgi ve deneyimlerinden yararlanarak, alanın nereye gittiğine ve ortaya çıkacak ihtiyaçların doğasına odaklanmaktadır (Söylemez, 2020, s. 271-291).

- Kalitatif (nitel) yöntem,
- Nicel (niceliksel) yöntemler.

3.4.1. Nitel (Kalitatif) Talep Tahmin Yöntemleri

Bu yöntemlerde bilgi işlem süreci uzmanlar tarafından gerçekleştirilir. Bazı yöntemler nicel yöntemler kadar yinelemeli olamasa ve beklentileri ifade ettikleri ve bu nedenle öznel yargılara dayandıkları için sonuçları tartışmalı olsa da nitel yöntemlerin kullanılmasını gerekli kılan belirli nedenler bulunmaktadır. Bunlar nitel tahmin yöntemlerinin en önemli avantajlarıdır. Ayrıca; nitel yöntemlerin avantajı, genellikle ucuz olmaları ve özel istatistiksel bilgi gerektirmemeleridir. Ancak nitel yaklaşımın dezavantajı, seçilen panelistlerin deneyimsiz olmaları, tahmin üzerine kendi düşüncelerini yansıtabilmeleri ve gelecek beklentileri nedeniyle tahmin üzerinde etkili olabilmeleridir (Yabar ve Aydın, 2020, s. 943-951).

3.4.1.1. Delphi Tekniğı

Delphi teknikleri, soru sorarak ve uzmanlardan fikir alarak sorunları çözmekle ilgilidir. Konu hakkında karar veren uzman ile görüşülerek karar verilebilmektedir. Delphi yöntemi genellikle anketler aracılığıyla gerçekleştirilir. Delphi teknikleri, bireylere farklı bilgi, beceri ve deneyimleri kullanarak bir problemin ilgili kısımlarına farklı bakış açılarından katkıda bulunma fırsatları sunmaktadır. Bu yöntemin dezavantajları řunlardır:

Özetle başarının uzmanın seçimine bağlı olduğu, sonuçların geri kazanılmasının zaman aldığı ve sürecin süresi uzadıkça katılımın azaldığı söylenebilir (Yalçın, 2020, s. 609-622).

3.4.1.2. Uzmanların Görüşleri Yöntemi

Şirket bünyesindeki üst düzey yönetici, uzman ve karar vericilerin kişisel görüş ve değerlendirmeleri birleştirilerek talep tahminleri oluşturulmaktadır. Görüşleri tahmin sürecine aktarırken; insanlarla doğrudan konuşmak, geleneksel toplantılar yaparak fikir birliğine varmak, beyin fırtınası yaparak sonuca varmak gibi çeşitli yöntemler kullanılmaktadır (Yaman ve Akgül, 2020, s. 29-42).

3.4.1.3. Pazar Araştırması Yöntemi

Pazar araştırması ve tüketici davranışı analizi, pazar talebini tahmin etmek için hayati bilgiler sağlamaktadır. Yöntem sadece tahmin için değil aynı zamanda ürün tasarımı geliştirme ve yeni ürün planlama için de kullanılabilir. Öte yandan bu, zaman alıcı ve pahalı bir yöntemdir (Yarat ve Orman, 2023, s. 72-85).

3.4.1.4. Satış Elemanlarının Görüşleri Yöntemi

Kullanımı ve anlaşılması kolaydır, insanlara hedef ve sorumluluklar ataması kolaydır ve bölge, ürün, müşteri ve tedarikçi bazında segmentlere ayrılabilir. Bir şirketin satış ekibi, müşterilerle doğrudan temas halinde oldukları ve piyasa gelişmelerini yakından takip ettikleri için sübjektif tahminler için etkili bir kaynaktır. Satıcılardan belirli bir zaman dilimi için tahmin sağlamaları istenmektedir. Yapılan tahminler daha sonra kapsamlı bir şekilde değerlendirilir ve nihai bir tahmin yapılmaktadır (Önen, 2020, s. 29-53).

3.4.1.5. Yaşam Eğrilerinin Benzeşimi Yöntemi

Bu kavram, bir şirketin ürün satışlarının zaman içinde, farklı dönemlerde veya aşamalarda gelişimine bakan basit yapılu bir model olarak ifade edilebilir.

Dayanıklılık, yaşam eğrisi vb. isimlerle ifade edilen bir ürünün yaşam döngüsünde dört ana aşama bulunmaktadır. Bunlar performans, büyüme, olgunluk ve düşüştür. Bu yöntem, benzer ürünlerin yaşam döngüsünün farklı zamanlarındaki satışlarına bakarak bir ürünün gelecekteki satışlarını tahmin etmeye çalışmaktadır (Aydın, 2022, s. 1-18).

3.4.2. Nicel (Kantitatif) Talep Tahmin Yöntemleri

Nicel yöntemler, geçmiş gözlemlere dayalı olarak analiz eden tahmine dayalı modelleri içermektedir. Kullanılan yöntem; incelenen değişkende gözlemlenen değişikliklerin analiz edilmesini, veri serisinin dinamik özelliklerinin belirlenmesini ve bu özelliklerin matematiksel fonksiyonlarda ifade edilmesiyle gelecek hakkında tahminler çıkarılmasını içermektedir. Nicel tahmin yöntemleri genel olarak iki gruba ayrılmaktadır (Bayyurt vd., 2023, s. 15-35).

3.4.2.1. İlişkiye Dayalı (Nedensel) Yöntemler

Nedensel veya ilişki tabanlı tahmin yöntemleri; Tahmin edilecek değişken çeşitli faktörlerden etkilendiği için bağımlı değişkenin etkilendiği veya bağlı olduğu diğer değişkenleri belirlemeye ve bu etkileri açıklamaya çalışmaktadır. Nedensel bir yaklaşım, değişkenlerin gelecekteki değerlerini tahmin etmekten çok, iki veya daha fazla değişken arasındaki ilişkiyi açıklamaya yöneliktir. İlişkiye dayalı (nedensel) yöntemler iki şekildedir (Özgür vd., 2023, s. 1-12).

- **Regresyon analizi;** Bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi matematiksel olarak ifade eden istatistiksel bir tekniktir. Bağımlı ve bağımsız değişkenler arasındaki ilişkiyi kuran parametrelerin değerlerini tahmin etmek için regresyon denklemleri kullanılır (Tekin ve Patır, 2023, s. 56-77).
- **Korelasyon analizi;** İki değişken arasındaki doğrusal ilişkiyi veya bir değişken ile iki veya daha fazla değişken arasındaki ilişkiyi test etmek ve eğer öyleyse ilişkinin boyutunu ölçmek için kullanılan istatistiksel bir yöntemdir. Korelasyon katsayılarını yorumlarken yapılan hatalardan biri,

sadece değerlerine bakarak iki değişken arasında güçlü bir etki ilişkisi çıkarabiliyorsanız, bir değişkeni neden, diğerini sonuç olarak kabul etmektir. İki değişken arasında dikkate alınmayan diğer değişkenleri de dikkate alarak çok değişkenli korelasyon hesaplama yöntemini kullanılmaktadır (Tüzüntürk ve Sert Eteman, 2023, s. 131-154).

3.4.2.2. Zaman Serisi Yöntemleri

Zaman serisi yöntemleri, olayların tarihsel verilerini incelemeye ve belirli eğilimleri tespit ederek geleceğe yönelik tahminler yapmaya dayanmaktadır. Bu yöntemlerin amacı, gözlemlenen verilerin geçmiş kalıplarına dayalı istatistiksel modeller oluşturmak ve bu kalıpları geleceği tahmin etmek için kullanılmaktadır. Bir zaman serisi, sürekli ve eşit mesafeli zaman aralıklarında bağımsız bir değişkenin değerlerini gösteren bir koleksiyon olarak tanımlanabilir (Akbaş, 2022, s. 97-110).

Konunun ihtiyacına göre zaman birimi olarak yıl, ay, üç ay, hafta, gün gibi zaman dilimleri kullanılabilir. Bir zaman serisinin gözlemlenen değerlerindeki değişiklikler, zaman içinde artış veya azalış olarak tanımlanabilir. Zaman serisi analizlerinde kullanılan tarihsel bilgilerde değişikliğe neden olan dört faktör bulunmaktadır (Demircan Keskin ve Soyuer, 2022, s. 15-20).

Trend bileşeni: Tarihsel bir serinin gözlemlenen değerlerinin uzun bir süre boyunca artma veya azalma yönündeki genel eğilimine “trend” denir.

Mevsimsel değişiklikler: Ardışık yıl, çeyrek, mevsim ve ayların aynı döneminde gözlenen değerlerin artış veya azalış şeklinde düzenli olarak değişmesini ifade etmektedir.

Devri hareketler: Mevsimsel değişikliklerden daha uzun bir süre boyunca meydana gelen değişikliklerdir.

Rassal hareketler Bu değişikliklerin nedenleri belirsizdir ve herhangi bir sistemik değişikliği ortaya çıkarmamaktadır (Öztürk ve Şahin, 2021, s.119-142).

Zaman Serilerinin Analizi; Zaman serilerini analiz etmeniz gerekiyorsa, zaman serisi bileşenlerinin etkisine bakmanız gerekmektedir. Neden; zaman serileri, tesadüf bileşeninin yanı sıra, diğer üç bileşenin farklı kombinasyonlarından

neredeyse aynı oranda etkilendiğinin belirlenmesi gerekmektedir. Bu kombinasyonların en kabuledilenleri Toplumsal ve Çarpımsal modeldir (Yıldız, 2021, s. 157-171).

Toplumsal modele; göre zaman serisinin herhangi bir andaki değeri (t) bu dört unsurun toplamıdır. Bu modele göre elemanların birbirini etkilemediği varsayılmaktadır. Bu model kullanılarak serideki herhangi bir elemanın oranı mutlak değer olarak belirlenebilmektedir (3.1).

$$Y_t = T_t + Mt + Kt + Rt \quad (3.1)$$

Çarpımsal modele; göre, herhangi bir andaki zaman serisi değeri (t), bu dört unsurun çarpımıdır. Bu modele göre öğeler birbirini etkilemelidir (3.2) (Güner ve Demir, 2022, s. 389-397).

$$Y_t = T_t * Mt * Kt * Rt \quad (3.2)$$

Naive Yöntemi; Mekanik bir model, en basit tahmin yöntemidir. Tahmin ile yapılan tahminin daha yüksek olup olmadığını belirlemek için de kullanılmaktadır. Bu yöntem, zaman serilerini dalgalanma olmadan tahmin etmek için sorunsuz bir yöntemdir. Çoğu zaman serisinde dalgalanmalar olduğu için bu yöntem çok kullanışlı değildir. Bu yöntemin temel avantajı, ileri zaman serisi yöntemleri için bir başlangıç değeri sağlamasıdır (3.3) (Eşidir vd., 2022, s. 260-277).

$$F_{t+1} = Y_t$$

t = dönem

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

Y_t = t dönemi için gerçekleşen değerdir. (3.3)

Hareketli Ortalamalar Yöntemi; Zaman serileri ne kadar rastgele olursa, ortalamadan sapma o kadar büyük olmaktadır. Bu rastgeleliği ortadan kaldırmak için son gözlenen değerlerin ortalamasını almak faydalı olabilmektedir.

Bunu yapmak için hareketli ortalama yöntemi, geçmiş verilerin ortalamasını alır ve bu ortalamayı gelecek dönemler için bir tahmin olarak kullanılmaktadır (Yıldırım ve Karaatlı, 2022, s. 1-29).

- **Basit hareketli ortalama:** Bu hareketli ortalama tekniğinde, nihai n tahmin olarak dönemin ortalamasını kullanılmaktadır.
- **Ağırlıklı hareketli ortalama:** Basit hareketli ortalama tahmin değerlerinin son hesabı n dönemin ortalamasını almak her n dönem aynı ağırlığa sahip olmaktadır.

Üstel Düzeltim Yöntemi; Üstel yumuşatma, tarihsel verilere eşit ağırlık veren, ancak tarihsel verilere eşit yerine farklı ağırlıklar veren basit hareketli ortalamalara benzer bir yöntem grubudur. “Üstel” terimi, verilerin eskidikçe ağırlığının katlanarak azaldığı anlamına gelmektedir. Başka bir deyişle, tahmin için kullanılan tarihsel verilere yüksek bir ağırlık verilir ve bu ağırlık, veri yaşlandıkça katlanarak azaltılmaktadır (Işık ve Şeker, 2021, s. 304-311).

Box-Jenkins yöntemi; Bu yöntem, tek değişkenli bir model olarak geleceği tahmin etme yöntemlerinden biridir. Kısa vadeli tahminlerde çok başarılı sonuçlar vermektedir. Yöntem birçok alternatif model arasından en iyi modeli seçerek geleceği tahmin etmeyi amaçlamaktadır. Değişkenler, gecikmeli değerleri, hata terimleri veya her ikisinin birleşimi kullanılarak tahmin edilmektedir (Kamber vd., 2021, s. 364-379).

3.4.3. Yapay Zekâ Tabanlı Yöntemler

Özellikle karmaşık problemleri çözerken yapay zeka tabanlı yöntemlerin güçlü teknikler olduğu kanıtlanmıştır. Literatürde talep tahmini için çeşitli yapay zekâ algoritmaları kullanılmaktadır. Bunlar arasında en çok kullanılanlar: yapay sinir ağları, bulanık mantık ve genetik algoritmadır. Bu, araştırmamızın üçüncü bölümünde kapsamlı bir şekilde incelenmiştir (Reşat, 2020, s. 1129-1140).

3.5. Tahmin Doğruluğunun Ölçümü

Kullanılan yöntem ne olursa olsun, tüm talep tahminlerinin belirli bir doğruluk düzeyi vardır ve hiçbir tahmin %100 doğru olmamaktadır. Bu nedenle baştan belirli bir hata oranını kabul etmek gerekir. Geleceği tahmin etmede tahmine dayalı bir modelin veya teknolojinin doğruluğunu test etmek için belirli kriterler

kullanılabilir. Tahmin edilen ve gerçek değerler arasındaki fark, farklı tekniklerin veya modellerin tahmin doğruluğunu karşılaştırmaya yardımcı olabilecek formüller kullanılarak tahmin edilir ve normalleştirilir. Talep tahmininin hassasiyetini değerlendirmek için yukarıdaki göstergelerden en az ikisi dikkate alınmalıdır. Yalnızca boyuta göre karar vermek rahatsız edici olabilir. Ölçüm yorumlamasındaki farklılıklar not edilmelidir (Yılmaz ve Özcan, 2020, s. 57-72).

3.6. Talep Tahmin Yönteminin Seçimi

Talep tahmin yönteminin seçimi hassasiyet, zaman tasarrufu ve maliyet açısından önemlidir. Bir tahmin yöntemi seçilirken, öncelikle tahmin prosedürünün hedefleri kesin olarak tanımlanmalı ve ardından karar verici tarafından belirli faktörler değerlendirilmelidir.

- **Bilim derecesi:** Kolay anlaşılır, uygulanabilir bir yaklaşım yöneticiler tarafından tercih edilmelidir.
- **Zaman:** Kapsanan süreyi tahmin etmek farklı bir yaklaşım gerektirebilir. Uzun vadeli tahminler için kalitatif yöntemler uygunken, kısa ve orta vadeli tahminler için kantitatif yöntemlere öncelik verilmelidir.
- **Karar Türü:** Tahmini sonuçlara ve gerekli hassasiyete dayalı uzun vadeli veya kısa vadeli kararlar gibi faktörler seçilen yöntemi belirlemektedir.
- **Maliyet:** Farklı tahmin yöntemleri farklı maliyet unsurlarına sahip olabilmektedir. Maliyet faktörünün işletme için önemi nedeniyle, yöntem seçilirken dikkate alınmalıdır.
- **Veri yolu:** Veriler, doğrusal veya eğrisel bir eğilimi, mevsimsel veya döngüsel değişimi veya rastgele bir dağılımı izleyebilmektedir. Bu nedenle verinin izlediği yolun belirlenmesi yöntem seçiminde oldukça önemlidir.
- **Bilişim Destek:** Bilgisayar programları, özellikle nicel yöntemler kullanılırken çok kullanışlı ve önemlidir (Vural, 2019, s. 1-42).

3.7. Yapay Sinir Ağları

Yapay sinir ağları, beynin işlevleri yerine getirme yeteneğini modelleyebilen sistemler olarak tanımlanabilir. Yapay sinir ağları, genellikle katmanlar halinde düzenlenmiş yapay sinir hücrelerinin birbirine bağlanmasıyla oluşturulur. Beynin bilgi işleme işlevine göre yapay sinir ağları, belli bir öğrenme süresinden sonra bilgiyi genelleme ve depolama yeteneğine sahiptir (Bingöl, 2023, s. 1-22)

Yapay sinir ağları, öğrenme, öğrenilenleri hatırlama ve önceki bilgilerden yeni bilgiler türetme gibi temel beyin fonksiyonlarını yerine getirmek için insan beyninin çalışmasından geliştirilen mantık tabanlı yazılımlardır. Çalışma mekanizmaları olarak biyolojik sinir ağlarını taklit etmektedirler (Şenol ve Denizhan, 2023, s. 42-69).

Yapay sinir ağları, basit biyolojik sinir sistemlerinin çalışma algoritmalarını taklit etmek için tasarlanmış programlardır. Simüle edilmiş sinir hücreleri, birbirine bağlı ve ağlar oluşturan nöronlar içerir. Bu ağlar, veriler arasındaki bağlantıları öğrenme, hatırlama ve keşfetme yeteneğine sahiptir (Tekin ve Patır, 2023, s. 56-77).

3.7.1. Tarihsel Gelişim

Warren McCulloch ve Walter Pitts, 1943'te bir sinir ağının ilk matematiksel modelini oluşturduklarında bu bilmeceyi yanıt aramışlardır. Yeni ufuklar açan kitabı "Nöral Aktivitede İçeren Düşüncenin Mantıksal Bir Hesaplaması", insan düşünce süreçlerini taklit etmek için tasarlanmış matematiksel algoritmalar önermiştir. 1960, çok gerçek anlamda sinirsel bilgisayarın yılı olmuştur.

Basit modelin eksiklikleri 1963'te keşfedildi, ancak 1970'ler ve 1980'lere kadar olumlu sonuçlar ortaya çıkmamıştır. 1985 yılına gelindiğinde, yapay sinir ağları iyi biliniyordu ve kapsamlı bir şekilde çalışılmaktaydı (Tüzüntürk ve Sert-Eteman, 2023, s. 131-154).

3.7.2. Yapay Sinir Ağlarının Kullanım Alanları

80’li yıllardaki gelişmeler sayesinde yapay sinir ağları ile problemler çözölüp lineer olmayan verilere adaptasyonları gösterildikten sonra ağlar; bunlar sistem kontrolü ve tanıma, görüntü ve ses tanıma, prognoz ve tahmin, hata analizi, tıp, iletişim, trafik ve üretim yönetimini içermektedir. Makine öğrenimi algoritmalarının kullanıldığı hemen hemen her alana uygulanabilmektedir. Yapay sinir ağları kullanılırken genel fikir, yapay sinir ağlarının günümüzde herhangi bir yöntemin yaptığı her türlü işlevi yerine getirebileceği ve geleneksel modelleme yöntemlerinden daha verimli çözümler sunabileceğidir (Acar ve Kumru, 2022, s. 91-101).

Yapay sinir ağlarının uygulamaları, ağın gerçekleştirdiği faaliyetlere göre şu şekilde gruplandırılabilir:

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

3.7.3. Yapay Sinir Ağları Yapısı

Yapay sinir ağları, farklı katmanlarda gruplanmış hücrelerden ve bu hücreler arasındaki bağlantılardan oluşur. Katmanlar, birbirine bağlı sinir hücrelerinin kümeleridir (Dinç ve Ulukavak, 2022, s. 181-192).

Bir yapay sinir ağı, nöron adı verilen birden fazla birimden oluşur. Ağ 3 veya daha fazla katmandan oluşan bir yapıya sahiptir. Ağda 1 giriş katmanı, 1 veya daha fazla gizli katman ve 1 çıkış katmanı vardır. Girdi katmanı, girdi bilgisini ağa aktaran girdi kümesidir. Giriş seviyesi ile çıkış seviyesi arasında birden fazla ara seviye olabilir. Bir katmandaki her bir nöron, bir üst katmandaki nöronlara farklı ağırlıklarla bağlıdır. Girdi katmanındaki tüm veriler ağırlık değeri ile çarpılarak gizli katmana iletilir. Sonuç gizli katmandaki transfer fonksiyonundan geçirilerek çıkış katmanına gönderilir. Gizli katmanda 0 ila 1 aralığında bir çıktı elde etmek için bir transfer

işlevi olarak doğrusal bir sigmoid işlevi kullanılabilir. Yapay sinir ağlarının boyutu kısaca iki ana kriterle temsil edilmektedir. Ağa ait katman sayısı ve gizli birim adettir (Harman, 2022, s. 1-12)

- Giriş katmanında, ham veriler ağa beslenmektedir. Bu seviyedeki elemanlar, dış dünyadan sisteme bilgi aktarımından sorumludur. Bazı ağlarda giriş seviyesinde bilgi işleme yapılmaz. Bu katmanın nöronları, problemin girdi parametrelerinin sayısına karşılık gelir ve her nöron, girdisi için verileri içermektedir.
- Gizli katman, sinir ağının işlemlerini yaptığı katmandır. Girdi katmanından gelen bilgilerin işlenmesinden ve çıktı katmanına iletilmesinden sorumludur. Bazı ağlarda birden çok ara katman yazılımı olabilir. Bu katman, kullanıcı tarafından görülmez ve giriş katmanı tarafından ağa sunulan verilerin, incelenen probleme uygun bir işlev kullanılarak işlendiği ve sonucun elde edilmesi için çıkış katmanına iletildiği yerdir.
- Ara katman verileri için uygun çıktı bilgilerinin üretilmesinden ve dış dünyaya gönderilmesinden sorumlu olan orta katmandan gelen bilgileri işlenmektedir. Çıkış katmanı ise, giriş katmanı aracılığıyla ağa sunulan ve gizli katmanda işlenen verilerin, ağın yapısına uygun bir fonksiyon kullanılarak işlendiği ve sonucu çıkış olarak sunduğu katmandır (Kurt, 2022, s. 808-822).

3.7.4. Yapay Sinir Ağlarının Genel Özellikleri

YSA'lar, donanım ve/veya yazılımda ortaya çıkabilecek sorunlara karşı dirençlidir, çözümlerinin algoritmik olarak formüle edilemediği sorunlar için kullanılabilir, birçok model davranış biçimine, verilere ve mevcut yapılara erişime sahiptir. YSA uygulamaları temel olarak tahmin, sınıflandırma, haritalama, veri yorumlama ve veri filtreleme için kullanılır (Saka Ilgın ve Sercan Sarı, 2022, s. 282-296). YSA'lar aşağıdaki temel özelliklere sahiptir:

- **Paralellik:** Yapay sinir ağları birbirinden bağımsız fakat aynı anda çalışan elemanlardan oluşur. Bu yapıda tüm ağın beklenen özellikleri hücrelere

paralel olarak yüklenir. Bu özellik, ağa hız ve dayanıklılık avantajları sağlar. Sinir ağlarında, işlemler doğrusal değildir ve ağ boyunca dağıtılır. Bu şekilde, karmaşık doğrusal olmayan problemleri çözmek mümkündür (Sarı, 2022, s. 282-296).

- **Öğrenebilirlik:** Yapay sinir ağlarının temel işlevi, bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek, benzer olaylarla karşılaştıklarında benzer kararlar almaya çalışırlar. Yapay sinir ağlarının istenen davranışı sergileyebilmesi için amaçlarına göre uyarlanması gerekmektedir. YSA'lar, eğitim sırasında işlenen verilerden öğrenerek genelleme yapabilmekte ve bu sonuçları daha önce karşılaşılmayan sorunları çözmek için kullanabilmektedir (Yıldırım ve Karaatlı, 2022, s. 1-29).
- **Hata toleransı:** Yapay sinir ağlarının paralel yapısı, ağdan gelen bilgilerin tüm bağlantılara yayılmasına izin verdiği için, belirli bağlantılardaki veya birimlerdeki verimsizlikler, ağın doğru bilgi üretmesinde önemli bir etkiye sahip değildir. Bu nedenle, hata ayıklama yetenekleri, geleneksel yöntemlere kıyasla son derece yüksektir (Can ve Şencan Şahin, 2021, s. 1154-1163).
- **Genelleme:** YSA'lar görmedikleri örnekler hakkında bilgi üretmek için kendilerine verilen örnekleri de kullanabilirler. Bir yapay sinir ağının eğitilecek bir olayı öğrenebilmesi için, o olayla ilişkili örneklerin tanımlanması gerekir. İlgili gerçek örnek veriler olmadan bir sinir ağını eğitemezsiniz. Ağ eğitiminde kullanılan örneklerin olayları temsil etmesi önemlidir. Örnek, olayın tüm yönleriyle birlikte ağa sunulursa, ağ iyi çalışır.
- **Dereceli Bozulma:** Ağ bir eksiklik veya sorunla karşılaştığında, ağ hemen çökmez. Hataya dayanıklı oldukları için kademeli olarak bozulurlar (Cansız vd., 2021, s. 342-354).
- **Uyarlanabilirlik:** YSA'lardaki ağırlıkların yeniden yapılandırılabilirliği, belirli bir sorunu çözmek için eğitilen YSA'ların geri dönüştürülebilmesini ve sorun değiştikçe farklı koşullara uyarlanabilmesini sağlar. Belirli bir sorunu çözmek için eğitilen bir yapay sinir ağı, sorun değiştikçe yeniden

eğitilebilir. Değişiklik olursa yerinde eğitime devam edilebilir. Bu yeteneği ile yapay sinir ağları, uyarlanabilir örüntü tanıma, sinyal işleme, teşhis ve sistem kontrolü gibi alanlarda etkin bir şekilde uygulanmaktadır (Cinel ve Yolcu, 2021, s. 492-508).

- **Donanım ve hız:** Bu özellik, yapay sinir ağlarının hızlı bilgi işleme yeteneklerini geliştirir ve bu da onları gerçek zamanlı uygulamalar için ilk tercih haline getirir.
- **Analiz ve Tasarım Kolaylığı:** Hücreler, yapay sinir ağlarının temel işlem elemanlarıdır ve tüm yapay sinir ağlarında yapıları ve modelleri aşağı yukarı aynıdır. Dolayısıyla çeşitli uygulama alanlarındaki yapay sinir ağlarının yapısı da bu standart yapıların birimlerinden oluşacaktır (Civelek, 2021, s. 375-381).

3.7.5. Yapay Sinir Ağlarının Avantajları

Yapay sinir ağları yöntemleri, özellikleri ve yetenekleri nedeniyle önemli avantajlara sahiptir. Bu bölümde yapay sinir ağlarının farklılıkları ve avantajları incelenmektedir. Ağ Bilgi Depolama: Bilgi, geleneksel programlamada olduğu gibi bir veritabanı yerine ağ üzerinde depolanır. Bir veya daha fazla bilgi parçasının kaybı, ağın işlevselliğini etkilemeyecektir. Yapay sinir ağları paralel işlemciler kullanır. Bir seri işlemcide, yavaş bir disk tüm sistemi yavaşlatırken, yapay sinir ağında yavaş bir diskin etkisi daha azdır. Bu durum yapay sinir ağlarını daha hızlı ve güvenilir hale getirmektedir. Yapay sinir ağlarının bir diğer önemli avantajı da temel özellikleridir. İnsan beyninin çalışma sisteminden ilham alan yöntem, eğitim yoluyla öğrenme veya verileri kullanarak doğrudan deneyimleme yeteneğine sahiptir.

Eksik bilgileri işleme yeteneği: Yapay sinir ağları, veriler eksik bilgiler içerdiğinde bile sonuç üretecek şekilde eğitilir. Burada performans cezası bilgi kaybetmenin öneminden kaynaklanmaktadır (Çörekcioglu vd., 2021, s. 14-20).

Yapay sinir ağlarının en önemli özelliklerinden biri gerçek hayatta ortaya çıkan doğrusal olmayan yapıları açıklayabilmeleridir. Özellikle, ekonomik veriler gibi doğrusal olmayan verileri içeren analizler, tahmin zorluğu nedeniyle genellikle doğrusal yöntemler kullanılarak gerçekleştirilir. Hata toleransı: Bir veya daha fazla

YSA hücresinin arızalanması çıktı üretmelerini engellemez. Bu özellik, ağı hataya dayanıklı hale getirir. Dağıtık belleğe sahiptir: Bir yapay sinir ağının öğrenebilmesi için örneklerin bulunması, bu örneklerin ağı sunulması ve ağın istenen çıktı üzerinde eğitilmesi gerekir. Ağın başarısı, seçilen şampiyonla doğru orantılıdır. Bir olayın tüm yönleri ağı sunulamıyorsa, ağ bunu yanlış raporlayabilir. Bir yapay sinir ağında bilgi ağ boyunca dağıtılır ve hücreler arasındaki bağlantı değerleri ağın bilgisini ortaya çıkarır (Ertaylan vd., 2021, s. 93-105).

Diğer programlarda olduğu gibi, veriler veritabanına veya programa entegre edilmez. Tek bir bağlantı anlamsızdır ve tüm ağ tüm öğrenme olayını temsil eder. Dolayısıyla yapay sinir ağlarının dağıtık bellekte bilgi depolayabildiği söylenebilir. Kademeli bozulma: Ağ, yavaş ve nispeten zaman içinde bozulur. Bir sorun olması durumunda ağın anında kesilmesi söz konusu değildir. Ağ bir eksiklik veya sorunla karşılaştığında, ağ hemen çökmez. Hataya dayanıklı oldukları için kademeli olarak bozulurlar. Makine öğrenimi yetenekleri: Yapay sinir ağları olaylardan öğrenebilir ve benzer olaylara açıklama ekleyerek kararlar alabilir. Yapay sinir ağları, bilgileri kendi ilişkilerini oluşturmak için kullanır ve denklem içermez. Ancak sistemin içinde neler olup bittiğini tam olarak analiz etmek mümkün değil. Paralel işlem yeteneği: YSA'lar aynı anda birden fazla görevi yerine getirebilecek sayısal yeteneğe sahiptir (Süleyman, 2021, s. 612-624).

3.7.6. Yapay Sinir Ağlarının Dezavantajları

Yapay sinir ağlarının eğitim süreci uzun ve karmaşık olabilir. Ağ oluşturma başarısı doğrudan bu eğitim süreciyle ilgilidir. İkincisi, bunlar ayrıntılı programlama yapıları olmadığı için çözümlerin nasıl ve neden ortaya çıktığı açıklanamaz ve kapalı kutular olarak tanımlanabilir. Donanım bağımlılığı: Yapısı gereği yapay sinir ağları, paralel bilgi işlem yeteneklerine sahip işlemciler gerektirir. Bu nedenle, uygulanması donanıma bağlıdır (Yürük, 2021, s. 282-289).

Açıklanamayan Ağ Davranışı: Yapay sinir ağlarının en büyük sorunudur. Yapay sinir ağları problemlere çözüm sunarken neden ve nasıl olduğunu söylemezler. Bu da ağı olan güveni azaltan bir faktördür. Uygun ağ yapısının belirlenmesi: Bir yapay sinir ağının yapısını belirlemek için belirli kurallar yoktur.

Doğru ağ yapısı deneyim ve deneme yanılma yoluyla elde edilir. Problemleri ağa sunma zorluğu: Yapay sinir ağları sayısal bilgileri işleyebilir. Problem YSA'ya beslenmeden önce sayısal değerlere dönüştürülmelidir. Burada tanımlanacak görüntüleme mekanizmaları doğrudan ağ performansını etkiler. Aynı zamanda kullanıcının yeteneklerine de bağlıdır. Ağ eğitim süresi bilgisi: Örneklerdeki ağ hatasını belirli bir değerin altına düşürmek, eğitimin tamamlandığı anlamına gelir. Bu değer bize en iyi sonuçları vermemektedir (Akbulut ve Özcan, 2020, s. 12-22).

3.7.7. Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağları, bir çözümü öğrenmek için örnekler kullanan bir yapıdır. Sürecin ilerleyen kısımlarında, henüz ortaya çıkmamış sorunlara benzer çözümler geliştirmek için bunun üzerine inşa edebilirler. Yapay sinir ağları ilk oluşturulduğunda, sinir hücreleri arasındaki bağlantılara rastgele kuvvetler atanıyordu. Model çalıştığında, veri setinin sonucu üzerinde tahminler yapılır. Bunu yaparak ağ, bağlantılarının gücünü kademeli olarak artırır ve eğitim, modelin sonuçlarında tutarlılık sağlar. Bugüne kadar, ağ öğrenimi için bağlantı güçlerini birbiriyle eşleştirmeyi içeren birçok algoritma geliştirilmiştir. Ağ eğitiminde kullanılan veri setlerinin yapısına bağlı olarak mevcut algoritmalar üç ana başlıkta toplanabilir (Cansız vd., 2020, s. 771-782).

3.7.7.1. Gözetimli Öğrenme

Bu öğrenme yöntemi ile YSA modelini eğitmek için girdi ve çıktı bilgileri ağa aktarılır. İstenen istatistiksel doğruluk elde edildiğinde eğitim tamamlanır. Burada tahmini değer gerçek çıkış değeri ile karşılaştırılır. Bu yöntemler arasında denetimli öğrenme tercih edilen öğrenme yöntemidir. Bir yapay sinir ağını eğitmek için oluşturulan eğitim veri setinin bir probleme ait önceki verileri içermesi ve bu verinin çözümünün de denetimli öğrenme olarak adlandırılmaktadır. Denetimli öğrenmede eğitim süresi, yapay sinir ağına tahmini sonuçlarının gerçek çözümle karşılaştırılması, sonuçların hata toleransının belirlenmesi ve ağı yapay nöronları arasındaki bağlantı gücünün güncellenmesinden oluşmaktadır (Çınaroğlu ve Avcı, 2020, s. 1-19).

3.7.7.2. Gözetimsiz Öğrenme

Bu öğrenme yönteminde, ağ öğrenimini destekleyecek bir kontrol mekanizması yoktur. Ağa sadece giriş değerleri iletilir ve bu değerlere karşılık gelen çıkış değerleri beklentisi bulunmamaktadır. Genellikle sınıflandırma problemlerinde kullanılır. Denetimsiz öğrenme, ağ eğitimi aşamasında ağ tarafından üretilen beklenen çözümlerle karşılaştırılacak gerçek dünya çözümlerinin olmaması anlamına gelir. Bu durumda sinir ağı modeli, girdinin ana özelliklerini matematiksel olarak keşfetmeye çalışır ve gözlemlenen değişikliklere dayalı olarak yanıt algoritmasını optimize etmektedir (Damla vd., 2020, s. 32-49).

3.7.8. Yapay Sinir Ağlarında Öğrenme Kuralları

Yapay sinir ağlarında öğrenme süreci, istenilen sonuca ulaşmak için bağlantı ağırlıklarının belirlenmesidir. Öğrenme, yapının mevcut örnekler üzerinde iyi çalışmasını sağlayan bağlantı ağırlıklarının hesaplanmasıdır. Yapay sinir ağı tarafından öğrenme sürecinde elde edilen bilgiler, sinir hücreleri arasındaki bağlantı ağırlıkları şeklinde depolanır. Bu ağırlık değerleri sinir ağının veri işlemesi için ihtiyaç duyduğu bilgilerdir (Erginer vd., 2020, s. 29-35).

Yapay sinir ağlarının öğrenme süreci çok parametrelili, karmaşık ve matematiksel olarak zor bir süreçtir. Günümüzde kullanılan öğrenme kuralları süreç için basitleştirilmiş veya farklı bir formatta ifade edilmiştir. Bu algoritmalar dört temel algoritmalar ve diğerleri bunlardan türetilmiştir. Bu; Hebb, Hopfield, Delta ve Kohonen kurallarıdır. Yapay sinir ağları için çeşitli öğrenme kuralı algoritmaları bulunmaktadır. Bu kurallar şu şekilde özetlenebilir (İlhan ve Öz, 2020, s. 160-188).

3.7.8.1. Hebb Kuralı

Hebb kuralı, sinir ağlarının bağlantı sayısı farklılaştırıldığında öğrenebileceğini varsaymaktadır. Bir nöron başka bir nörondan girdi aldığı ve iki nöron güçlü bir şekilde bağlandığında, kısaca matematiksel ifadenin aynı işaretiyle, internöronun ağırlıkları güçlenir. Bir reseptör ve bir verici nöron arasındaki iki

sinaptik ağırlık aynı işarete sahipse, bu iki nöron arasındaki bağlantı güçlendirilmelidir. Aksi halde bağlantı gücü azaltılmalıdır. Hebb öğrenme kuralına göre öğrenme sinyali hücrenin gücüne eşittir. Diğer bir deyişle, bir birim aktif olduğunda kendisine bağlı birimi aktif hale getirme, pasif olduğunda ise o birimi pasif hale getirme eğilimi göstermektedir (Kantar, 2020, s. 121-131).

3.7.8.2. Hopfield Kuralı

İşlemci elemanın yapay sinir ağına bağlantısının ne derece güçleneceğini veya zayıflayacağını belirlemek için, beklenen çıktı ve girdi aktif veya pasif olduğunda öğrenme katsayıları ile ağırlık değerleri güçlendirilir veya zayıflatılır. Başka bir deyişle, ağırlıkları güçlendirmek veya zayıflatmak için öğrenilen katsayıları kullanmaktadır. Öğrenme katsayısı genellikle 0 ile 1 arasında sabit bir pozitif değerdir. Bu kural, Hebb kuralına benzer ve aynı zamanda bağ gücündeki değişimin büyüklüğünü de belirtir. Bu kurala göre; Öğrenme oranı arttıkça bağlantının gücü artar veya azalır. Öğrenme oranı pozitif veya negatif bir değerdir. Uygulamada öğrenme oranı 0 ile 1 arasında seçilmektedir (Kara ve Özcan, 2020, s. 155-176).

3.7.8.3. Kohonen Kuralı

Genellikle bir ağ, danışmanlar olmadan kendi kendine büyüyebilir. Bu aynı zamanda düğümlerin en uygun sonucu paralel olarak belirleme rekabeti sayesinde de mümkündür. Sistem, girişleri gruplandırmak için kullanılan özellikleri belirlemektedir. Bunu yapmak için, ağ bağlantı ağırlıklarının başlangıç değerlerini çizmek ve girişi normalleştirmek gerekmektedir. Ağırlık vektörü giriş vektörüne en yakın olan işlemci elemanı kazanan ilan edilir ve bağlantı ağırlıklarının güncellenmesi için diğer birimlere iletmektedir (Kılıç vd., 2020, s. 379-391).

3.7.8.4. Delta Kuralı

Delta kuralı, günümüzde en yaygın kullanılan öğrenme yöntemlerinden biridir. İlkesi, gerçek çıktı ile beklenen çıktı arasındaki farkı azaltmak için yapay

sinir ağıının işlem elemanları arasındaki bağlantı ağırlıklarını sürekli olarak değiştirmektedir. Bu kural, gerçek çıktı ile beklenen çıktı arasındaki farkı en aza indirmeye çalışmaktadır. Hebb kuralının genişletilmiş halidir. Beklenen ve gerçek performans arasındaki farkı en aza indirmek için ağırlıkların periyodik olarak değiştirilmesi gerektiğini kabul edilmektedir. Ağdaki hataları en aza indirmek için ağırlıklar sürekli olarak güncellenmekte ve temelde en küçük kareler kuralına dayanmaktadır (Kıral ve Çelik, 2020, s. 1-21).

Özetle, Delta kuralının amacı, sinir ağıının kök ortalama kare hatasını en aza indirmektir. Artımlı öğrenme kuralına göre, sinir ağı işlemci elemanlarının ağırlık değerleri, beklenen çıktı ile gerçek çıktı arasındaki farkı azaltmak için en küçük kareler ortalaması minimize edilene kadar sürekli olarak değiştirilir (Sel vd., 2020, s. 157-169).

3.7.9. Yapay Sinir Ağı Çeşitleri

Yapay sinir ağları, nöron veya düğüm adı verilen işlem elemanlarından oluşur. Yapay sinir ağlarının modelleri, sinirleri birbirine bağlayan bağlantıların yönü veya ağ içindeki sinyal akışının yönü bakımından birbirinden farklılık göstermektedir. Bu modeller iki gruba ayrılır: İleri besleme ve geri besleme yapay sinir ağ çeşitleridir. YSA'lar, mevcut çıkışın kesikli veya sürekli olmasına bağlı olarak iki şekilde görselleştirilebilir. Kesikli değişkenlerden oluşan girdiler sınırlı sayıda niteliksel değer alabilirken; sürekli değişkenler ise uzunluk ve ağırlık gibi sayısal olarak ölçülebilen değerlerdir (Urgan ve Tamgöz, 2020, s. 8-14).

3.7.9.1. İleri Beslemeli Ağlar

İleri beslemeli ağlarda bilgi aktarımı, girdi katmanı, gizli katman ve çıktı katmanı sırasında gerçekleşir. Bu akış tek yönlüdür ve geri besleme yoktur. Bir katmandaki yapay nöronlar, önceki YSA hücreleri tarafından beslenmektedir. İleri beslemeli bir ağda, işleme elemanları genellikle katmanlara bölünmektedir. Sinyal, giriş seviyesinden çıkış seviyesine tek yönlü bir bağlantı yoluyla aktarılır. İşlemci elemanları katman katman bağlı olsalar da, aynı katman içinde bağlı değildirler. Bir

sinir ağıının tahmini girdi katmanında, veriler işlenmeden bir sonraki katmana gönderilir. Gizli katmandaki işlemci eleman sayısı, uygulanan problemin girdi sayısına bağlı olarak sistem veya tasarımcı tarafından belirlenebilir (Yılmaz ve Kılıcı, 2020, s. 133-146).

3.7.9.2. Geri Beslemeli Ağlar

Varsayılan olarak, geri besleme durumu çıkıştan girişe doğru geriye dönük hatayı azaltmaya çalışmaktadır. İlgili geribildirim ağı modelinde girdi, gizli ve çıktı olarak adlandırılan üç katman vardır. Ancak problemin özellikleri dikkate alınarak gizli katman sayısı arttırılabilir. Geri bildirim, hem katman içindeki işlemci öğeleri arasında hem de katmanlar arasındaki işlemci öğeleri arasında gerçekleşebilir. Bu yapı nedeniyle, yapay geri beslemeli sinir ağları doğrusal olmayan dinamik davranış sergilemektedir. Bu sayede geri besleme türüne göre farklı yapı ve davranışlara sahip yapay sinir ağları elde edilebilir. Geri beslemeli yapay sinir ağları karmaşık çalışma mekanizmalarına rağmen dinamik bellekleri sayesinde tahmin uygulamalarında olumlu sonuçlar vermektedirler (Tekin, 2023, s. 319-355).

3.7.10. Yapay Sinir Ağları Çalışma Prosedürü

Bir yapay sinir ağıının çalışma mekanizması sırasıyla aşağıdaki adımlarda gerçekleşir. Öğrenme parametreleri: Öğrenme katsayısı ve momentum katsayısının yanı sıra toplama işlevi ve aktivasyon işlevi tespit edilmelidir. Ağırlıkların başlangıç değerlerinin belirlenmesi: Giriş değerleri ile ara katmanlar arasından (-0.1, 0.1) aralığında ağırlıklar rastgele seçilmektedir. Çalışma setinden örnekler seçilerek ve ağda sunularak, çalışma setinin içeriği ağda görüntülenir. Eğitim sırasında ek hesaplamalar: Girdi vektörleri için çıktıları ve sonuçta ortaya çıkan hata değerlerini belirlenmektedir. Gerçek çıktının tahmini çıktıyla karşılaştırılması; Gerçek çıktı değerini beklenen çıktı değeriyle karşılaştırmak ve farkı ağ hatası olarak belirlenmelidir. Ağırlıklardaki değişiklikler; Geri hesaplamada, toplam hata ağ bağlantılarının ağırlıklarına yayılır. Örnekler grubu: Bu, geçmişte web’de yayınlanan durum örneklerinin bir koleksiyonudur. Ağ topolojisinin belirlenmesi; Ağın

katmanlarının ve bu katmanlardaki işlem elemanı sayısının belirlenmesidir (Korkmaz, 2020, s. 91-109).

3.7.11. Yapay Sinir Ağları ve Tahmin Modelleri

Üreticiler ve perakendeciler gibi birçok tedarikçi de tam satışlarını tahmin etmek istemektedirler. Özellikle perakendeciler, geçmiş satış verilerine dayanarak envanterlerinin ne kadarının satıldığını belirlemekte zorlanmaktadırlar. Bu ihtiyacı karşılamak için büyük veri tabanlarını analiz etmek için yapay sinir ağları kullanılmaktadır (Bayyurt ve Deveci Kocakoç, 2023, s. 15-35).

İdeal koşulların yokluğunda, yapay sinir ağları talebi tahmin etmede regresyon yöntemlerinden daha iyidir. Regresyona göre daha sağlıklı sonuç elde edilen durumlar gösterilmektedir. Matematiksel bir modelde tahmin yaparken, varsayımlar değişkenler arasındaki ilişkiyi açıklayan işlevler olmalıdır. Bir yapay sinir ağı böyle bir yapıya ihtiyaç duymaz ve bağımsız değişkenler arasında bir ilişki olup olmadığını kendi kendine öğrenebilir (Altın ve Çelik Eroğlu, 2020, s. 540-562).

Tersine, nitel modeller bireysel düşünce ve fikirleri içerirken, nicel modeller öznellikten uzak sorunlara çözüm aramak için istatistiksel ve matematiksel yöntemler kullanan modellerdir.

Ağ, genelleme yetenekleri sayesinde, eğitim sırasında hiç karşılaşmadığı durumları analiz edebilmektedir. Ağ, ayrık fonksiyonları tanımlayabildiğinden, doğrusal olmayan problemlere de uygulanabilmektedir (Demircan Keskin ve Soyuer, 2022, s. 15-20).

3.8. ANFIS Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi

ANFIS, Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi veya Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi anlamına gelmektedir. ANFIS kelimesi (Adaptive Neuro-Fuzzy Inference System) kelimelerinin baş harflerinden oluşmuştur. Bulanık sinir ağları, bulanık mantık ve yapay sinir ağı yöntemlerinin faydalı yönlerini öne çıkaran ve son yıllarda birçok farklı alanda uygulanmaya başlayan yapay sinir ağlarıdır (Okwu vd., 2023, s. 1266-1279).

ANFIS, Jang tarafından 1993 yılında önerilmiş olup uyarlanabilir ağ tabanlı bulanık çıkarım sistemleri (ANFIS), belirli bir problem için oluşturulan yapıya göre olası tüm kuralları atayabilir veya uzmanların verileri kullanarak kural atamasına olanak tanımaktadır (Lawal vd., 2021, s. 265-277).

ANFIS yalnızca Sugeno modellerini yönetmektedir. Mamdani tarzı modellemenin bir modifikasyonu olup giriş verilerine uygulanan işlemler aynı aralarındaki tek fark çıktı verileridir. Sugeno tarzı modellemede, çıktı değişkeninin girdiye dayalı bir üyelik fonksiyonu vardır ve çıktı üyelik fonksiyonunun doğrusal veya sabit olması gerekmektedir. ANFIS, Matlab bulanık mantık araç kutusunda bulunan bir fonksiyon dosyasıdır. Program, bulanık çıkarım tekniklerini verilen verilere uygular ve karşılık gelen bir veri modeli oluşturmaktadır. Diğer bulanık çıkarım sistemlerinde olduğu gibi ANFIS'teki üyelik fonksiyonları da parametrelere bağlanmaktadır. Parametreler değiştiğinde üyelik fonksiyonu da değişir ve ANFIS kendisine bir üyelik fonksiyonu atmaktadır (Mousazadeh vd., 2021, s. 2-8).

ANFIS yalnızca faaliyetleri tahmin etmek veya tek çıkışlı doğrusal olmayan fonksiyonları tahmin etmek için kullanılabilir. Bu nedenle yapay sinir ağları birçok tahmin probleminde uzman görüşlerinden faydalanabilir ve ortalama karesel hata kriterinden daha iyi sonuçlar elde edebilmektedir. Giriş ve çıkış değerleri, geri yayılım öğrenme algoritmasını veya en küçük kareler yöntemini kullanarak bu değerlerden bulanık çıkarım modeli oluşturan ANFIS'e iletilmektedir. Kuralın sonuç kısmı girdinin doğrusal bir fonksiyonu olarak tanımlanmaktadır. Bu sistem izleme, zaman serisi tahmini, gürültü giderme, sınıflandırma, tespit ve eğri uydurma gibi birçok alanda başarıyla uygulanmaktadır. ANFIS modelleme tekniğini basitleştirmek için bulanık çıkarım sistemi iki giriş x ve y ve bir çıkış z ile değerlendirilmektedir. Aynı zamanda kural tabanının aşağıda tartışılacağı gibi Takagi ve Sugeno tipi iki eğer-o halde kuralından oluştuğu genel olarak kabul edilmektedir. Şekil 1'de bulanık çıkarım sistemi gösterilmektedir (3.4) (Lawal vd., 2021, s. 265-277).

Kural 1: Eğer x , A_1 ve y , B_1 ise $f_1=p_1x+q_1y+r_1$


Kural 2: Eğer x , A_2 ve y , B_2 ise $f_2 = p_2x+q_2y+r_2$

...

Kural n : Eğer x , A_n ve y , B_n ise $f_n=p_nx+q_ny+r_n$

(3.4)

şeklinde belirtilmektedir.




Şekil 1. Bulanık Çıkarım Sistemi

Kaynak: Lawal, A.I., Kwona, S., Hammed, O.S., ve Idris, M.A. (2021). Blast-induced ground vibration prediction in granite quarries: An application of gene expression programming, anfis, and sine cosine algorithm optimized ann. *International Journal of Mining Science and Technology*, Contents Lists Available at Scienedirect, 31(1), 265–277.

3.8.1. ANFIS Mimarisi

Bulanık “eğer-on” kurallarına dayalı olarak oluşturulan ANFIS ağ yapısı, giriş bulanık üyelik fonksiyonu, bulanık çarpma, normalizasyon, toplama ve Sugeno tipi doğrusal çıkış fonksiyon katmanlarını içermektedir. ANFIS yapısı 5 katmanlı bir mimariye sahiptir. ANFIS'te beş katman vardır ve her katmandaki sinirler aynı işlemleri içermekte olup katmandaki farklı şekillerdeki düğümler, farklı işlevlere sahip özellikleri bulunmaktadır. Kare formda temsil edilen düğümlere uyarlanabilir düğümler adı verilir ve düğümlerin parametreleri ağ eğitimi sırasında ayarlanmaktadır. Dairelerle temsil edilen düğümler değişmeyen katı düğümlerdir. Şekil 2’de Anfis Mimarisi gösterilmektedir (Mousazadeh vd., 2021, s. 2-8). Katman özellikleri aşağıdaki gibidir:



Şekil 2. Anfis Mimarisi

Kaynak: Mousazadeh, F., Naeem, M.H.T., Daneshfar, R., Soulgani, B.S., ve Naseri, M. (2021). Predicting the condensate viscosity near the wellbore by elm and anfis-pso strategies. *Journal of Petroleum Science and Engineering*, Contents lists available at ScienceDirect, 204(1), 2-8.

Seviye 1: Bulanıklaştırma katmanında, üyelik fonksiyonu olarak çan eğrisinin genelleştirilmiş aktivasyon fonksiyonu kullanılarak giriş değerleri bulanık kümeler bölünmektedir. ANFIS Bulanıklaştırma Katmanı-1 formülasyonu gösterilmektedir (3.5).

$$\mu_{Ai}(x; a_i, b_i, c_i) = \frac{1}{1 + \left[\frac{(x - c_i)^2}{a_i^2} \right]^{b_i}} \quad (3.5)$$

Seviye 2: Denetleme düzeyi olup, bu katmanın her düğümü, Takagi-Sugeno bulanık çıkarım sistemine dayalı olarak oluşturulan kuralları ve bunların sayısını temsil etmektedir. Her kural düğümünün sonucu, birinci düzeydeki uyumun ürünüdür. ANFIS Denetleme Düzeyi Katmanı-2 formülasyonu gösterilmektedir (3.6).

$$\theta_i^2 = w_i = \mu_{Ai}(x_1) \times \mu_{Bk}(x_2) \quad i=(1..66), j=(1,2,3) \text{ ve } k=(1..5) \quad (3.6)$$

Seviye 3: Burada her düğüm, tüm seviye 2 düğümlerini giriş değeri olarak kabul eder ve her kuralın standartlaştırılmış tetikleme seviyesini hesaplamaktadır. ANFIS Standartlaştırılmış Katman-3 formülasyonu gösterilmektedir (3.7).

$$\theta_i^3 = \overline{w_i} = \frac{w_i}{\sum_i w_i} \quad (3.7)$$

Seviye 4: İyileştirme katmanı olarak adlandırılan bu seviyede Takagi-Sugeno bulanık çıkarım yöntemi kullanılarak oluşturulan kuralların ağırlıklı sonuçlarının değerleri hesaplanmaktadır. ANFIS Saflaştırma Katmanı-4 formülasyonu gösterilmektedir (3.8).

$$\theta_i^4 = \overline{w_i} f_i = \overline{w_i} (p_i x_1 + q_i x_2 + r_i) \quad (3.8)$$

Seviye 5: Bu toplama düzeyidir ve yalnızca bir düğüme sahiptir. ANFIS sisteminin gerçek çıkış değeri, üst katmandaki düğümlerin çıkış değerlerinin eklenmesiyle elde edilmektedir (Okwu vd., 2023, s. 1266-1279). ANFIS Toplama Düzeyi Katmanı-5 formülasyonu gösterilmektedir (3.9).

$$\theta_i^{\bar{}} = y = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \tag{3.9}$$



4. UYGULAMA

X Group, Türkiye merkezli köklü bir yapı sektörü şirketidir. 1995 yılında kurulan firma, iskele sistemleri ve kalıpcılık alanında uzmanlaşmıştır.

4.1. Firma Tanıtımı

Müşterilerine inşaat sektöründe kullanılan çeşitli ekipman ve malzemelerin üretimi, satışı ve kiralama hizmetlerini sunarak sektörde önemli bir konum edinmiştir. X Group İskele, kalite, güvenlik ve yenilikçilik ilkeleriyle faaliyet göstermektedir. Müşteri memnuniyetini ön planda tutan firma, sektördeki en son teknolojileri ve en iyi uygulamaları benimseyerek, müşterilerine yüksek kaliteli ürünler ve profesyonel hizmetler sunmaktadır. Firmanın ana ürün ve hizmetleri arasında şunlar bulunmaktadır;

İskele Sistemleri: X Group, çeşitli inşaat projelerinde güvenli çalışma platformları sağlamak için özel tasarlanmış iskele sistemleri üretir ve kiralar. Esnek ve modüler tasarımları sayesinde, farklı proje gereksinimlerine kolaylıkla uyum sağlayabilirler.

Kalıpcılık Malzemeleri: Betonarme yapıların kalıplama süreçlerinde kullanılan kalıp panelleri, aksesuarlar ve diğer ilgili malzemeleri üreten X Group, yüksek kaliteli ve dayanıklı ürünleriyle sektörde güvenilir bir isim haline gelmiştir.

Kiralama Hizmetleri: Müşterilerin kısa veya uzun vadeli projeleri için gerekli olan ekipmanları temin etmelerine yardımcı olmak amacıyla, X Group İskele kiralama hizmetleri sunmaktadır. Geniş ürün yelpazesi ve esnek kiralama seçenekleriyle müşterilere uygun çözümler sunulmaktadır.

Ayrıca, X Group'un teknik destek, danışmanlık ve proje yönetimi gibi ek hizmetleri de bulunmaktadır. Firmanın sektördeki deneyimi ve uzmanlığı, müşterilere projelerinde başarı ve verimlilik sağlama konusunda güven vermektedir.

İnşaat sektöründe sürdürülebilir büyüme ve başarı için kaliteli ürünler ve müşteri odaklı hizmetler sunarak sektörde öncü bir konumda yer almaktadır.

4.2. Araştırmanın Modeli

Bu çalışmada bir inşaat iskelesi üretimi yapan fabrikanın 2022-2023 yılı ait haftalık satış bilgileri toplanmıştır. Bu işletme için talepler yurtdışında bulunan merkez satış ofisinden gelmektedir. Bu kapsamda çalışmamızda firmamızın aşağıdaki sorunlarına çözüm aranacaktır;

- Satış ofisi bulunan her ülkenin dönemsel olarak satışları artmakta ve azalmaktadır. Yani talep dengesizliği ortaya çıkmaktadır.
- Satış ofisleri öncelikle kendi depolarındaki stoğu kontrol edip satış için yeterli miktar olup olmadığına bakmaktadır. Eğer varsa satışı yapıp minimum stok değerinin altında kalan ürünler için merkez depodan ürün istemektedir. Merkez depo ise minimum stoğunu tamamlamak için Türkiye’de bulunan fabrikadan ürünleri talep etmektedir. Üretim süreci ve lojistik sürelerinin uzun olmasından dolayı herhangi bir gecikme veya eksik talep miktarı büyük zararlara yol açmaktadır.
- Mevcut sistemde talep tahminlemesi yalnızca daha önceki yılların aynı dönemindeki miktarların aritmetik ortalaması alınarak yapılmaktadır. Bu yüzden bazen stok yetersizliği bazen de fazla stok problemi yaşanmaktadır.

Yapay sinir ağları metodu, giriş verisi miktarındaki artmayla doğru orantılı olarak daha tutarlı sonuçlar üretebilmektedir. Yapay sinir ağları diğer metotlarla birçok çalışmada karşılaştırmalı olarak incelenmiş ve sonuç olarak özellikle sabit olmayan ve kesikli veri serilerinin bulunduğu durumlarda, oldukça tutarlı ve güvenilir sonuçlar ürettiği görülmüştür. Yapay sinir ağı modeli, her biri büyük bir problemin farklı parçası ile ilgilenen çok sayıda işlemciden oluşması ve bağlantı ağırlıklarının ayarlanabilir olması gibi özelliklerinden dolayı, esnek bir yapıya sahiptirler. Bu esnek yapı sayesinde, ağın bir kısmı zarar görse bile model yinede çalışmaktadır. Bu durum sadece performans düşüklüğüne sebep olmakta fakat modelin işlevini tamamen yitirmesi söz konusu olmamaktadır.

4.3. Talebi Etkileyen Faktörler

İnşaat sektöründeki genel ekonomik koşullar, inşaat iskelesi talebini etkilemektedir. Örneğin, ekonomik büyüme dönemlerinde genellikle inşaat faaliyetleri artar ve bu da iskele talebini artırmaktadır. Bir bölgede gerçekleştirilen inşaat projelerinin sayısı ve büyüklüğü, iskele talebini belirlemektedir. İnşaat sektöründe mevsimsel dalgalanmalar yaygın olmaktadır. Özellikle kış aylarında inşaat faaliyetleri genellikle azalırken, yaz aylarında artmakta bu durum, iskele talebini de etkilemektedir.

Çalışmada yer alan firmamızın satışları genellikle Avrupa ülkeleri ve çeşitli ülkeler de olduğu için bir ülkenin satışları azalırken diğer ülkenin satışları artış göstermektedir. Bu faktörlerin incelenmesi, yapay sinir ağları (YSA) ve ANFIS gibi yöntemlerle talep tahmini yapılırken kullanılan modellerin doğruluğunu artırabilir ve işletmenin stratejik planlamasına katkı sağlayacağı düşünülmektedir.

4.4. Verilerin Toplanması

Çalışmamıza konu olan firmamız ile ilgili talep tahmini yaparken öncelik teşkil eden durum kullanılacak verilerin toplanmasıdır. Bu aşama, çalışmanın tüm doğruluğunu ve geçerliliğini belirleyecek ilk adımı olacaktır. Geçmiş döneme ait satış, tedarik, üretim süreleri gibi veriler olmadan tahmin yapmak mümkün değildir. Dolayısıyla talep tahmin aşamalarının ilk adımı verilerin toplanmasıdır. Verilerin toplanması aşamasından sonra ise dönemin belirlenmesi, talep tahminin başarısını etkileyen diğer aşama olmaktadır. Eğer yapılan tahmin haftalık ise ve elde edilen veriler aylık periyotta kullanılacaksa, tahminin başarı ihtimali düşük olmaktadır. Bu durumda, gerçekleştirilen bütün planların başarısız olmasına, bu nedenle de işletmenin ciddi maliyetlerle karşılaşmasına neden olmaktadır.

Bu çalışmada kullanılan veriler bir üretim işletmesinde 4 yıl boyunca satış yapılan gerçek miktarlardır. Veriler ERP (Enterprise Resource Planning) programı olanı SAP Business One üzerinden alınmıştır. Gün bazında çekilen satış raporları excel üzerinden haftalık satış miktarına dönüştürülmüştür.

4.4.1. Veri Seti Açıklaması

ItemCode: Ürünler için benzersiz tanımlayıcılar. Bu kodlar, ürünlerin çeşitli kategorilere ayrılması ve analiz edilmesi için kullanılmaktadır. Örneğin, ürünlerin stoğunu izlemek, satış performansını değerlendirmek için bu kodlar gerekmektedir.

Quantity: Satılan ürünlerin sayısı. Bu veri, her bir ürünün belirli bir tarihte ne kadar satıldığını göstermektedir. Satış miktarındaki değişiklikler, talep analizleri ve stok yönetimi için kritik bir bilgidir.

Date: Satışın gerçekleştiği tarih ve saat bilgisi. Zaman serisi analizi yapmak için kullanılır ve zaman içindeki değişimleri gözlemlemeye olanak tanımaktadır. Bu veri, mevsimsel etkiler, tatiller ve diğer zamanla ilişkili değişkenlerin analizine olanak sağlamaktadır.

USD: Satış tarihindeki Amerikan Doları kuru. Döviz kurları, özellikle uluslararası ticaret yapan firmalar için önemlidir. Bu veri, döviz kurlarındaki değişimlerin ürün maliyetlerini nasıl etkileyebileceğini anlamak için kullanılmaktadır.

EUR: Satış tarihindeki Euro kuru. USD gibi, bu da döviz kurlarının ürün fiyatları ve maliyetleri üzerindeki etkilerini analiz etmek için kullanılmaktadır.

Minimum_Wage: Satış tarihindeki asgari ücret. İş gücü maliyetlerinin ürün maliyetlerini nasıl etkileyebileceğini analiz etmek için kullanılır. Yüksek asgari ücretler, üretim maliyetlerini artırabilmektedir.

Iron_Price: Demir fiyatı. Demir, birçok endüstride önemli bir hammadde olduğundan, demir fiyatlarındaki değişiklikler üretim maliyetlerini etkileyebilmektedir. Bu veri, hammadde maliyetlerini izlemek ve tahminler yapmak için kullanılmaktadır.

Holiday: Tarihin tatil olup olmadığını belirten bir gösterge. Tatil günlerinde genellikle alışveriş alışkanlıklarında değişiklikler gözlemlenmektedir. Bu bilgi, tatil dönemlerindeki talep değişikliklerini anlamak için kullanılmaktadır.

4.4.2. Veri İşleme Aşamaları

Tarih Formatı Dönüştürme: Date sütunu, tarih ve saat bilgilerini daha anlamlı bir formatta dönüştürmektedir. Bu işlem, pandas kütüphanesi kullanılarak yapılır ve tarihsel veri analizi için temel bir adımdır.

Ek Özellikler Oluşturma:

- **Gün, Ay, Yıl:** Tarihten çıkarılan bu özellikler, mevsimsel ve yıllık döngülerin analiz edilmesine yardımcı olmaktadır.
- **Hareketli Ortalama (Moving Average):** Bir zaman dilimindeki değerlerin ortalamasını alarak trendlerin belirlenmesine yardımcı olur. Hareketli ortalama, kısa vadeli dalgalanmaların üzerini örtmeye ve genel trendleri ortaya koymaya yardımcı olmaktadır.
- **Üssel Hareketli Ortalama (Exponential Moving Average):** Daha yakın tarihli verilere daha fazla ağırlık verir, bu da kısa vadeli trendlerin daha iyi yakalanmasını sağlamaktadır.
- **Aritmetik Ortalama (Arithmetic Mean):** Verinin tüm tarih aralığındaki ortalamasını almaktadır.

Eksik Değerlerin Doldurulması: Hareketli ortalamalar gibi bazı işlemler eksik değerler üretebilmektedir. Bu eksik değerler, uygun yöntemlerle doldurulmaktadır (örneğin, önceki değerlerle doldurma).

Aşırı Uç Değerlerin Kaldırılması: Aşırı uç değerler, veri analizini bozar ve modelin doğruluğunu etkilemektedir. Bu yüzden, IQR (Interquartile Range) yöntemi kullanılarak belirlenen sınırlar dışında kalan değerler veri setinden çıkarılmaktadır.

0 (sıfır) Değerlerinin Doldurulması: Satış miktarındaki 0 değerler, ortalama değerlerle değiştirilmektedir. Bu, veri setinin tamamındaki tutarsızlıkları ve eksiklikleri yönetmektedir.

Sütunların Düzenlenmesi: Kullanılabilir veri özellikleri, modelleme için uygun bir formatta yeniden düzenlenmektedir.

4.4.3. Veri Setini Haftalık Olarak Yeniden Düzenleme ve Ölçeklendirme

Haftalık Toplama: Günlük veriler haftalık verilere dönüştürülür. Bu, uzun vadeli trendlerin ve döngülerin analizini kolaylaştırmaktadır.

Veriyi Ölçeklendirme: Veriler genellikle $[0, 1]$ aralığına dönüştürülür. Bu, modelin eğitim sürecinde daha iyi performans göstermesine yardımcı olur çünkü tüm özellikler aynı ölçeğe getirilmektedir.

4.5. Yapay Sinir Ağları ile Talep Tahmini Uygulaması

Bu bölümde YSA model oluşturma ve eğitme, YSA model değerlendirme ve YSA sonuçların görselleştirilmesi ve tablo halinde sunulması sonuçlarına yer verilmektedir.

4.5.1. YSA Model Oluşturma ve Eğitim

1. Model Tanımlama:

- **LSTM Katmanları:** Uzun vadeli bağımlılıkları öğrenme yeteneğine sahip özel bir sinir ağı katmanıdır. Bu, zaman serisi verilerinde gelecekteki değerlerin tahmin edilmesine yardımcı olmaktadır.
- **Dense Katmanlar:** Modelin çıktısını oluşturur. İlk Dense katmanı, daha fazla özellik çıkarımı yaparken, ikinci Dense katmanı tahmin sonuçlarını vermektedir.

2. Modeli Derleme ve Eğitim:

- **Kayıp Fonksiyonu (Loss Function):** `mean_squared_error`, modelin tahminleri ile gerçek değerler arasındaki farkı ölçmektedir.
- **Optimizer:** adam optimizer'ı, ağırlıkların güncellenmesini yönetir ve öğrenme sürecini optimize etmektedir.
- **Early Stopping:** Modelin aşırı öğrenmesini (overfitting) önler ve en iyi performansı sağlamak için erken durdurma sağlamaktadır.

4.5.2. YSA Model Değerlendirme

Tahminlerin Ters Ölçeklendirilmesi: Model tahminleri ve gerçek değerler, orijinal ölçeklerine geri dönüştürülür. Bu, sonuçların daha anlamlı ve karşılaştırılabilir hale gelmesini sağlamaktadır.

4.5.3. YSA Sonuçların Görselleştirilmesi ve Tablo Halinde Sunulması

1. Grafik Çizimi:

Gerçek ve Tahmin Edilen Değerlerin Karşılaştırılması: Grafikler, modelin performansını görselleştirir. Gerçek değerlerle tahmin edilen değerler arasındaki farkları net bir şekilde göstermektedir.

2. Sonuç Tablosu:

Tahminler ve Gerçek Veriler: Sonuçların tablo halinde sunulması, modelin performansını detaylı bir şekilde incelemeye olanak tanır ve modelin başarısını değerlendirmektedir. Tablo 1’de model tahmin sonuçları tablosu ve Tablo 2’de YSA metrikleri gösterilmektedir.

Tablo 1. Model Tahmin Sonuçları Tablosu


Tarih	Gerçek Değerler	YSA Tahmin Değerleri (%70 Eğitim)	YSA Tahmin Değerleri (%80 Eğitim)
7.11.2022	4.578	7.971	4.438
14.11.2022	6.908	5.904	6.490
21.11.2022	7.414	3.616	2.321
28.11.2022	3.857	3.312	2.270
5.12.2022	6.290	9.899	8.065
12.12.2022	5.057	4.267	1.073
19.12.2022	5.250	4.743	6.971
26.12.2022	4.317	7.400	5.101
2.1.2023	8.419	6.571	8.761
9.1.2023	5.422	6.165	3.376
16.1.2023	6.841	4.219	3.674
23.1.2023	22.586	19.117	18.497

Kaynak: Yazar tarafından oluşturulmuştur


Tablo 2. YSA Metrikler

Training Data %	MSE	RMSE	MAE	R ²
70	10.309.561,22	3.210,85	4.250,14	0,797
80	11.411.479,18	3.378,09	4.113,13	0,807
Test Data %	MSE	RMSE	MAE	R ²
30	6.127.247,26	2.475,33	2.117,47	0,739
20	6.858.748,02	2.618,92	2.095,54	0,781


Kaynak: Yazar tarafından oluşturulmuştur



Şekil 3. Tahmin Değerleri (%70 Eğitim Verisi)



Şekil 4. Tahmin Değerleri (%80 Eğitim Verisi)



Şekil 5. Tahmin Değerleri (%80 Eğitim Verisi ve %70 Eğitim Verisi)

4.6. ANFIS ile Talep Tahmini Uygulaması

ANFİS kütüphanesinin oluşturulması, model tanımlama ANFIS (Adaptive Neuro-Fuzzy Inference System) ve modeli derleme ve eğitme analiz sonuçlarına yer verilmektedir.

Tablo 3. Tahminler

Tarih	Gerçek Değerler	ANFIS Tahmin Değerleri	ANFIS Tahmin Değerleri	YSA Tahmin Değerleri	YSA Tahmin Değerleri
		(%70 Eğitim)	(%80 Eğitim)	(%70 Eğitim)	(%80 Eğitim)
7.11.2022	4.578	6.354	4.639	7.971	4.438
14.11.2022	6.908	7.576	7.763	5.904	6.490
21.11.2022	7.414	3.825	9.600	3.616	2.321
28.11.2022	3.857	3.825	8.990	3.312	2.270
5.12.2022	6.290	10.944	6.206	9.899	8.065
12.12.2022	5.057	3.849	7.451	4.267	1.073
19.12.2022	5.250	4.547	2.037	4.743	6.971
26.12.2022	4.317	5.093	6.197	7.400	5.101
2.1.2023	8.419	9.733	10.376	6.571	8.761
9.1.2023	5.422	5.093	10.041	6.165	3.376
16.1.2023	6.841	2.061	4.583	4.219	3.674
23.1.2023	22.586	18.444	21.504	19.117	18.497

Kaynak: Yazar tarafından oluşturulmuştur

Tablo 4. ANFIS Metrikler

Training Data %	MSE	RMSE	MAE	R ²
70	4.634.509,14	2.152,79	1.531,44	0,817
80	5.361.743,93	2.315,54	1.775,23	0,803
Test Data %	MSE	RMSE	MAE	R ²
30	6.878.691,17	2.622,73	1.997,72	0,714
20	6.907.482,11	2.628,21	2.143,52	0,757

Kaynak: Yazar tarafından oluşturulmuştur

4.6.1. ANFİS Kütüphanesinin Oluşturulması

ANFİS (Adaptive Neuro-Fuzzy Inference System) adlı bir modelin TensorFlow ve Keras kullanarak uygulanmasını sağlıyor. ANFİS, bulanık mantık (fuzzy logic) ve yapay sinir ağlarını (neural networks) birleştiren bir modeldir. Bu model, giriş değişkenleri ile çıkış değişkenleri arasında bulanık kurallar kullanarak ilişki kurmaktadır. Kodun bileşenleri şu şekildedir:

1. fis_parameters Sınıfı:

- ANFİS modeli için hiperparametreleri tanımlar.
- Giriş sayısı (n_input), üyelik fonksiyonu sayısı (n_memb), batch boyutu (batch_size), epoch sayısı (n_epochs), üyelik fonksiyonu tipi (memb_func), optimizasyon algoritması (optimizer) ve kayıp fonksiyonu (loss) gibi parametreleri içerir.

2. ANFİS Sınıfı:

- ANFİS modelini oluşturan ana sınıftır.
- __init__ metodu, ANFİS modelini tanımlar ve modelin katmanlarını oluşturur.
- __call__ metodu, modeli çağırarak tahminler yapar.
- update_weights metodu, modelin ağırlıklarını günceller.
- plotmfs metodu, üyelik fonksiyonlarını grafiksel olarak çizer.
- fit metodu, modeli eğitim verisi üzerinde eğitir.
- get_memberships metodu, giriş verilerine göre üyelik değerlerini hesaplar.

3. Özel Katmanlar:

- FuzzyLayer: Giriş verilerine göre üyelik fonksiyonlarını hesaplar.
- RuleLayer: Bulanık kurallar katmanıdır. Giriş üyelik fonksiyonlarının kombinasyonlarını hesaplar.
- NormLayer: Kural katmanının çıkışlarını normalize eder.

- DefuzzLayer: Normalize edilmiş üyelik fonksiyonlarının doğrusal bir kombinasyonunu kullanarak bulanık çıkarımı (defuzzification) gerçekleştirmektedir.

- SummationLayer: Sonuçları toplar ve modelin tahmin ettiği değerleri üretmektedir.

4. Custom Weight Initializer:

- `equally_spaced_initializer` fonksiyonu, üyelik fonksiyonlarının parametreleri için başlangıç ağırlıklarını eşit aralıklarla oluşturmaktadır.

Bu yapı, ANFIS modelinin girişleri olarak çıkış tahminlerini yapmasını sağlar ve aynı zamanda modelin eğitilmesini mümkün kılar. Kod, ANFIS'in klasik yapısını sinir ağı mantığı ile birleştirerek bu tahminleri daha esnek hale getirmektedir.

4.6.2. Model Tanımlama: ANFIS (Adaptive Neuro-Fuzzy Inference System)

ANFIS Modeli: ANFIS, yapay sinir ağları ile bulanık mantığın bir kombinasyonudur. Bu model, doğrusal olmayan ve belirsiz veri setleri üzerinde oldukça etkili tahminler yapılabilmektedir. Model, giriş değişkenlerini bulanıklaştırarak, bulanık kurallar kullanarak sonuçları hesaplar ve sinir ağı öğrenme yetenekleriyle bu sonuçları optimize etmektedir.

Girişler: Model, 6 adet giriş değişkeni kullanır: USD, EUR, Minimum_Wage, Iron_Price, Holiday, ve Moving_Average bu değişkenler, modelin zaman serisi verisi üzerinde daha doğru tahminler yapmasını sağlamak için seçilmiştir.

Üyelik Fonksiyonları: Her giriş değişkeni için 3 adet Gaussian üyelik fonksiyonu tanımlanmıştır. Bu fonksiyonlar, giriş değişkenlerinin hangi bulanık kümelerle ait olduğunu belirlemektedir.

4.6.3. ANFİS Modeli Derleme ve Eğitim


- Modelin Derlenmesi: ANFIS modeli, adam optimizasyon algoritması ile derlenmiştir. Mean Squared Error (MSE) kayıp fonksiyonu, modelin tahminleri ile

gerçek değerler arasındaki ortalama karesel hatayı hesaplar ve modelin öğrenme sürecini yönlendirmektedir.


- Erken Durdurma (Early Stopping): Modelin aşırı öğrenmesini (overfitting) önlemek için, erken durdurma mekanizması eklenmiştir. Bu mekanizma, doğrulama kaybı belirli bir süre boyunca iyileşmediğinde eğitimi durdurarak modelin en iyi performansını korumaktadır.

- Modelin Eğitimi: Model, %70 ve %80 eğitim veri oranları ile iki ayrı eğitim süreciyle eğitilmiştir. Her iki durumda da, model 100 epoch boyunca eğitim almıştır ve en iyi sonuçları elde etmek için erken durdurma kullanılmıştır. Modelin eğitimi, test verisi üzerinde doğrulama yapılarak izlenmiş ve en iyi sonuçlar elde edilmiştir.


Bu şekilde, ANFIS modeli hem kısa vadeli hem de uzun vadeli eğilimleri yakalayabilecek şekilde optimize edilmiştir. Modelin performansı, farklı eğitim veri oranlarıyla test edilmiş ve karşılaştırılmıştır.



Şekil 6. Tahmin Değerleri (%70 Eğitim Verisi)



Şekil 7. Tahmin Değerleri (%80 Eğitim Verisi)



Şekil 8. Tahmin Değerleri (%80 Eğitim Verisi %70 Eğitim Verisi)

4.7. Anfis ve YSA Tahminlerinin Karşılaştırılması

Bu bölümde YSA sonuçlarına, ANFİS model tanımlama sonuçlarına, modeli derleme ve eğitime sonuçlarına, ANFİS modeli derleme ve eğitime sonuçlarına ve Anfis ve YSA tahminlerinin karşılaştırılması analiz sonuçlarına yer verilmiştir.

4.7.1. YSA Analizleri

1. Grafik Çizimi:

Gerçek ve Tahmin Edilen Değerlerin Karşılaştırılması: Grafikler, modelin performansını görselleştirmektedir. Gerçek değerlerle tahmin edilen değerler arasındaki farkları net bir şekilde göstermektedir.

2. Sonuç Tablosu:

Tahminler ve Gerçek Veriler: Sonuçların tablo halinde sunulması, modelin performansını detaylı bir şekilde incelemeye olanak tanır ve modelin başarısını değerlendirmektedir.

4.7.2. ANFİS Model Tanımlama Analizleri

ANFİS Modeli: ANFİS, yapay sinir ağları ile bulanık mantığın bir kombinasyonudur. Bu model, doğrusal olmayan ve belirsiz veri setleri üzerinde oldukça etkili tahminler yapabilmektedir. Model, giriş değişkenlerini bulanıklaştırarak, bulanık kurallar kullanarak sonuçları hesaplar ve sinir ağı öğrenme yetenekleriyle bu sonuçları optimize etmektedir.

Girişler: Model, 6 adet giriş değişkeni kullanılır: USD, EUR, Minimum_Wage, Iron_Price, Holiday, ve Moving_Average bu değişkenler, modelin zaman serisi verisi üzerinde daha doğru tahminler yapmasını sağlamak için seçilmiştir.

Üyelik Fonksiyonları: Her giriş değişkeni için 3 adet Gaussian üyelik fonksiyonu tanımlanmıştır. Bu fonksiyonlar, giriş değişkenlerinin hangi bulanık kümelerine ait olduğunu belirlemektedir.

4.7.3. ANFİS Modeli Derleme ve Eğitim Analizleri

- Modelin Derlenmesi: ANFİS modeli, adam optimizasyon algoritması ile derlenmiştir. Mean Squared Error (MSE) kayıp fonksiyonu, modelin tahminleri ile gerçek değerler arasındaki ortalama karesel hatayı hesaplar ve modelin öğrenme sürecini yönlendirmektedir.


- Erken Durdurma (Early Stopping): Modelin aşırı öğrenmesini (overfitting) önlemek için, erken durdurma mekanizması eklenmiştir. Bu mekanizma, doğrulama kaybı belirli bir süre boyunca iyileşmediğinde eğitimi durdurarak modelin en iyi performansını korumaktadır.

- Modelin Eğitimi: Model, %70 ve %80 eğitim veri oranları ile iki ayrı eğitim süreciyle eğitilmiştir. Her iki durumda da, model 100 epoch boyunca eğitim almıştır ve en iyi sonuçları elde etmek için erken durdurma kullanılmıştır. Modelin eğitimi, test verisi üzerinde doğrulama yapılarak izlenmiş ve en iyi sonuçlar elde edilmiştir.

Bu şekilde, ANFİS modeli hem kısa vadeli hem de uzun vadeli eğilimleri yakalayabilecek şekilde optimize edilmiştir. Modelin performansı, farklı eğitim veri oranlarıyla test edilmiş ve karşılaştırılmıştır.

4.7.4. ANFİS ve YSA Tahminlerinin Karşılaştırılması Analizleri

Bu bölümde ANFİS ve YSA tahminlerinin karşılaştırılması için mevcut grafik ve tablolar yer almaktadır.



Şekil 9. ANFİS ve YSA Tahminlerinin Karşılaştırılması Analiz Sonuçları

Tablo 5. ANFİS ve YSA Tahminlerinin Karşılaştırılması Tablosu

Tarih	Gerçek Değerler	ANFIS Tahmin Değerleri	ANFIS Tahmin Değerleri	YSA Tahmin Değerleri	YSA Tahmin Değerleri
		(%70 Eğitim)	(%80 Eğitim)	(%70 Eğitim)	(%80 Eğitim)
7.11.2022	4.578	6.354	4.639	7.971	4.438
14.11.2022	6.908	7.576	7.763	5.904	6.490
21.11.2022	7.414	3.825	9.600	3.616	2.321
28.11.2022	3.857	3.825	8.990	3.312	2.270
5.12.2022	6.290	10.944	6.206	9.899	8.065
12.12.2022	5.057	3.849	7.451	4.267	1.073
19.12.2022	5.250	4.547	2.037	4.743	6.971
26.12.2022	4.317	5.093	6.197	7.400	5.101
2.1.2023	8.419	9.733	10.376	6.571	8.761
9.1.2023	5.422	5.093	10.041	6.165	3.376
16.1.2023	6.841	2.061	4.583	4.219	3.674
23.1.2023	22.586	18.444	21.504	19.117	18.497

Kaynak: Yazar tarafından oluşturulmuştur

Tablo 6. ANFİS ve YSA Metriklerinin Karşılaştırılma Tablosu

Training Data %		MSE	RMSE	MAE	R ²
ANFIS	70	4.634.509,14	2.152,79	1.531,44	0,817
ANFIS	80	5.361.743,93	2.315,54	1.775,23	0,803
Test Data %		MSE	RMSE	MAE	R ²
ANFIS	30	6.878.691,17	2.622,73	1.997,72	0,714
ANFIS	20	6.907.482,11	2.628,21	2.143,52	0,757
Training Data %		MSE	RMSE	MAE	R ²
YSA	70	10.309.561,22	3.210,85	4.250,14	0,797
YSA	80	11.411.479,18	3.378,09	4.113,13	0,807
Test Data %		MSE	RMSE	MAE	R ²
YSA	30	6.127.247,26	2.475,33	2.117,47	0,739
YSA	20	6.858.748,02	2.618,92	2.095,54	0,781

Kaynak: Yazar tarafından oluşturulmuştur

SONUÇ

Ticari bir tesiste prosesleri dengelemek için optimum çalışma noktalarının, çoklu değişkenlere bağımlılığı nedeniyle sınırlı olması proseslerin geri döndürülemez bir şekilde deaktivasyonunu önlemek, çalışma sınırlarını aşmadan belirli üretim hedeflerini garanti eden çalışma koşullarının gelişmiş optimizasyon stratejileri geliştirmek gereklidir. Bu nedenle, kontrolörün içinde simülasyonlar veya kullanımlarını gerçekleştirmemize izin veren proses modellerine sahip olmak çok önemlidir. Ancak, prosesin matematiksel modelleri çözünürlüklerinde çok karmaşıktır, bu nedenle akıllı kontrol tekniklerine dayalı yaklaşımlarda kullanılmak üzere çok yüksek tepki süreleri üretilebilmektedir. Bu nedenle, kontrol stratejilerinin veya gerçek kontrol sisteminin tasarımı için sürelerde bir azalmaya izin veren bir proses modeli elde etmek için yeni bir stratejiye gerek duyulmaktadır. Özellikle son yıllarda hesaplamalı bilimlerin gelişmesi, farklı ticari prosesler bağlamında bir devrime neden olmuş ve yeni süreçlerin ve ürünlerin geliştirilmesi için deneysel maliyetlerde önemli azalmalar meydana gelmektedir. Hesaplamalı bilimlerin endüstriyel düzeye çıkarılması ve süreçlerin optimizasyonu, titiz bir kinetik model bilgisini gerektirmektedir. Ancak, proses reaksiyonların mekanizmalarının karmaşıklığı, fiziksel taşıma olaylarının önemi, bu verilerin yönetimi ve analizi için deneysel tekniklerin ve hesaplamalı yöntemlerin sınırlamalarıyla birleştiğinde, bu tarz proses çalışmalarını büyük ölçüde engellemektedir. Bu sınırlamaları azaltmanın bir yolu, özellikleri nedeniyle karmaşık süreçleri modellerken iyi sonuçlar sağlayan yapay sinir ağlarının (YSA) ve ANFİS (Adaptive Neuro-Fuzzy Inference System) kullanılmasıdır.

Bu çalışmada bir inşaat iskelesi üretimi yapan fabrikanın 2022-2023 yılı ait haftalık satış bilgileri toplanmıştır. İşletme için talepler yurtdışında bulunan merkez satış ofisinden gelmektedir. Bu kapsamda çalışmamızda firmamızın satış ofisi bulunan her ülkenin dönemsel olarak satışları artmakta ve azalmaktadır. Yani talep dengesizliği ortaya çıkmaktadır. Satış ofisleri öncelikle kendi depolarındaki stoğu kontrol edip satış için yeterli miktar olup olmadığına bakmaktadır. Eğer varsa satışı yapıp minimum stok değerinin altında kalan ürünler için merkez depodan ürün istemektedir. Merkez depo ise minimum stoğunu tamamlamak için Türkiye’de bulunan fabrikadan ürünleri talep etmektedir. Üretim süreci ve lojistik sürelerinin

uzun olmasından dolayı herhangi bir gecikme veya eksik talep miktarı büyük zararlara yol açmaktadır. Mevcut sistemde talep tahminlemesi yalnızca daha önceki yılların aynı dönemindeki miktarların aritmetik ortalaması alınarak yapılmaktadır. Bu yüzden bazen stok yetersizliği bazen de fazla stok problemi yaşanmakta olup bu sorunlara çözüm aranmıştır.

Çalışmamız kapsamında elde edilen veriler ve analizler sonucunda yapay sinir ağları metodu, giriş verisi miktarındaki artmayla doğru orantılı olarak daha tutarlı sonuçlar üretebilmektedir. Yapay sinir ağları diğer metotlarla birçok çalışmada karşılaştırmalı olarak incelenmiş ve sonuç olarak özellikle sabit olmayan ve kesikli veri serilerinin bulunduğu durumlarda, oldukça tutarlı ve güvenilir sonuçlar ürettiği görülmüştür. Yapay sinir ağı modeli, her biri büyük bir problemin farklı parçası ile ilgilenen çok sayıda işlemciden oluşması ve bağlantı ağırlıklarının ayarlanabilir olması gibi özelliklerinden dolayı, esnek bir yapıya sahiptirler. Bu esnek yapı sayesinde, ağın bir kısmı zarar görse bile model yinede çalışmaktadır. Bu durum sadece performans düşüklüğüne sebep olmakta fakat modelin işlevini tamamen yitirmesi söz konusu olmamaktadır.

Aşağıdaki tabloda YSA ve ANFIS modelleri ile MSE (Mean Squared Error), RMSE (Root Mean Squared Error), MAE (Mean Absolute Error) ve ortalama R^2 (Korelasyon Katsayısı) değerleri elde edilmiş olup Tablo 6'da ANFİS ve YSA metriklerinin karşılaştırılma tablosu gösterilmektedir.

Çalışmamız kapsamında literetürde yapılan farklı bir çalışmada Ayyildiz vd., (2021) yapay sinir ağları (YSA) ile COVID-19'dan iyileşen vakaların tahmini ile ilgili uygulama MLP modelleri, farklı parametre değerleriyle MATLAB R2020b yazılım ortamında geliştirilmiştir. Veri kümesiyle aşırı uyumu önlemek için “k” katlı çapraz doğrulama kullanılmıştır. En iyi parametre kombinasyonunu belirlemek için tahmin performansını farklı eğitim ve test yüzdelerindeki MSE'lere göre karşılaştırılmasında MSE değerleri hesaplanırken, ağ her dağılım için 100 kez çalıştırılmış ve rastgelelik ortalama değerler hesaplanarak elde edilmiş 80/20 eğitim/test ayrımı durumunda en iyi tahmin performans sonucunu verdiğini tespit etmişlerdir. Bu şekilde, en düşük hata oranını veren test ve eğitim verilerinin ayrımı başarıyla belirlendiği sonucuna varmışlardır.

1. MSE (Mean Squared Error):

ANFIS, %70 ve %80 eğitim verisi ile daha düşük MSE değerlerine sahiptir. %70 eğitim verisiyle ANFIS'in MSE değeri 4.634.509,14, YSA'nın ise 10.309.561,22'dir. Bu, ANFIS'in hata kareleri ortalamasının YSA'ya göre daha düşük olduğunu ve daha isabetli tahminler ürettiğini gösterir. Test verisi açısından, %30 test verisi ile YSA modeli (6.127.247,26), ANFIS'e göre daha düşük MSE değerine sahiptir (6.878.691,17). Bu, YSA'nın test verisinde daha iyi bir genelleme yapabildiğini ve performansının test verilerinde daha yüksek olabileceğini göstermektedir.

Yapılan farklı bir çalışmada Sorrosal vd., (2017) alkali ile muamele edilmiş bir HZSM-5 katalizörü üzerinde biyoetanol-olefinlere (BTO) dönüşüm sürecinin yapay sinir ağları (YSA) kullanılarak kinetik modellemesi sunulmuştur. Ana hedef, mekanik bir bilgi modeline göre hesaplama maliyetinin basitleştirilmesine ve azaltılmasına olanak tanıyan istenen doğrulukta bir BTO süreci nöronal modeli elde edilmiştir. YSA temel model yapılarının iyiliğini kontrol etmek için, çalışma sırasında destek vektör makineleri gibi diğer alternatif modelleme teknikleriyle bir karşılaştırma yapılmıştır. Bir parametre optimizasyon prosedürünü takiben ve farklı eğitim yöntemlerini test ederek, optimum YSA yapısının Bayes düzenleme eğitim yöntemi ile ileri beslemeli 3-5-1 ağı olduğu tespit edilmiştir. Laboratuvar ölçekli sabit yataklı bir reaktörde elde edilen bir dizi deneysel veriyi kullanarak, bilgi modeline benzer bir uyum elde ettik ancak 43 kata kadar daha hızlı olma avantajına sahip olduğu sonucuna varmışlardır.

2. RMSE (Root Mean Squared Error):

ANFIS'in RMSE değeri, hem %70 hem de %80 eğitim verisi ile YSA'ya göre daha düşüktür. ANFIS %70 eğitim verisi ile 2.152,79 RMSE'ye sahipken, YSA için bu değer 3.210,85'tir. Bu, ANFIS'in tahmin ettiği değerlerin gerçek değerlere daha yakın olduğunu gösterir. Test verisinde YSA modeli (%30 test verisi ile 2.475,33 RMSE) ANFIS modelinden (%30 test verisi ile 2.622,73 RMSE) daha düşük bir hata oranı göstermiştir. Bu, YSA'nın test verisinde daha stabil sonuçlar verdiğini gösterebilir.

Çalışmamız kapsamında literatürde yapılan farklı bir çalışmada Zainuddin vd., (2019), ön yükleme ve çift ön yükleme yapay sinir ağlarının yeni bir hibridizasyonu kullanılarak zaman tahmin modellerinin iyileştirilmesi ile ilgili ilk olarak ön yükleme modelinin ve çift ön yükleme modunun sırasıyla ön yükleme yapay sinir ağı-otoregresif entegre hareketli ortalama (B-ANFIS-ARIMA) ve çift önyükleme yapay sinir ağı-otoregresif entegre hareketli ortalama (DB-ANFIS-ARIMA) olarak adlandırılan hibritleşmesi önerilmektedir. İkincisi, bu önerilen modellerin performansını ARIMA, ANFIS ve ANFIS-ARIMA ile karşılaştırılarak SSE, MSE, RMSE, MAE, MAPE ve VAF üzerinde istatistiksel analiz yapılarak önerilen modellerin önceki ARIMA, ANFIS ve ANFIS -ARIMA modellerinden daha iyi olduğu tespit edilmiştir. Çalışmanın ampirik sonuçları, ARIMA, ANFIS'ler ve ANFIS-ARIMA modelleriyle karşılaştırıldığında önerilen modellerin hem eğitim hem de test veri kümeleri için daha küçük SSE, MSE, RMSE, MAE, MAPE ve VAF değerleri ürettiğini göstermektedir. Başka bir deyişle, önerilen modelleri karşılaştırdığımız modellerden daha iyi tahmin değerleri gerçek değerlere daha yakın ve önerilen modellerin daha yüksek doğruluk, verimlilik ve zaman serisi sonuçlarını tahmin etmede hassasiyet ile daha iyi tahmin değerleri üretmek için kullanılabileceği sonucuna varmışlardır.

3. MAE (Mean Absolute Error):

ANFIS'in MAE değerleri (%70 eğitim ile 1.531,44 ve %80 eğitim ile 1.775,23), YSA'nın değerlerine (%70 eğitim ile 4.250,14 ve %80 eğitim ile 4.113,13) göre çok daha düşüktür. Bu da ANFIS'in ortalama mutlak hatalarının YSA'ya kıyasla oldukça küçük olduğunu ve daha doğru sonuçlar üretebildiğini gösterir. Test verilerinde, YSA modeli %30 test verisi ile daha düşük MAE (2.117,47) değerine sahiptir. Ancak %20 test verisinde ANFIS (2.143,52) ve YSA (2.095,54) değerleri birbirine oldukça yakındır. YSA'nın test verisindeki bu performansı, modelin genelleme yeteneğinin güçlü olduğunu gösterir.

Çalışmamız kapsamında literatürde yapılan farklı bir çalışmada Zhu vd., (2020), DTOF-ANFIS; karar ağacı ve optimum özelliklere dayalı yapay sinir ağı kimlik avı tespit modelinde, karar ağacı ve optimum özellik seçimine dayalı bir sinir ağı kimlik avı tespit modeli olan DTOF-ANFIS (karar ağacı ve optimum özelliklere

dayalı yapay sinir ağı) önerilmektedir. İlk olarak, geleneksel “*K-medoid*” kümeleme algoritması, yinelenen noktaları genel veri kümelerinden kaldırmak için başlangıç merkezlerinin artımlı bir seçimiyle iyileştirilerek yeni tanımlanmış özellik değerlendirme endeksi, karar ağacı ve yerel arama yöntemine dayalı bir optimum özellik seçimi algoritması, olumsuz ve işe yaramaz özellikleri ayıklamak için tasarlanmıştır. Son olarak, sinir ağı sınıflandırıcısının optimum yapısı, parametreleri düzgün bir şekilde ayarlayarak ve seçilen optimum özelliklerle eğitilerek oluşturmuşlardır. Deneysel sonuçlar, DTOF-ANFIS’in mevcut yöntemlerin çoğundan daha yüksek performans gösterdiğini sonucuna varmışlardır.

4. R^2 Korelasyon Katsayısı:

R^2 değerleri açısından ANFIS modeli (%70 eğitim ile 0,817) YSA’ya (%70 eğitim ile 0,797) göre daha yüksek bir doğruluk oranına sahiptir. Bu, ANFIS’in eğitim verisi üzerindeki tahmin doğruluğunun daha yüksek olduğunu göstermektedir. %80 eğitim verisi ile her iki modelin R^2 değerleri birbirine çok yakındır (ANFIS 0,803; YSA 0,807), bu da YSA’nın daha fazla eğitim verisiyle ANFIS’e kıyasla daha güçlü performans gösterebildiğini işaret eder.

Test verilerinde YSA, %30 test verisinde daha yüksek bir R^2 değerine (0,739) sahiptir ve %20 test verisinde ise YSA’nın R^2 değeri (0,781) ANFIS’e göre (0,757) daha yüksek kalmaktadır. Bu, YSA’nın test verisinde daha başarılı bir model olduğunu gösterir.

Çalışmamız kapsamında literatürde yapılan farklı bir çalışmada Chen vd., (2021) heyelan duyarlılığını haritalamak için uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS) modelini optimize etmek için öğretim tabanlı optimizasyon (TLBO) ve Satin Bowerbird Optimizer (SBO) algoritmaları kullanmışlardır. Çalışma alanında 152 heyelan tespit etmişler ve bunları rastgele eğitim veri seti (%70) ve doğrulama veri seti (%30) olarak iki gruba ayırmışlardır. Ayrıca heyelanı etkileyen toplam 15 faktör seçilmiştir. Adım adım ağırlık oranı analizi (SWARA) yöntemi, farklı etkileyici faktörlerin göreceli önemini ve ağırlığını belirlemek için kullanmışlar son olarak, iki modelin genel performansı, ortalama kare hatası (RMSE), işlem süresi, yakınsama ve alıcı işletim karakteristikleri altındaki alan (AUROC) gibi çeşitli ölçümler kullanılarak yapılan karşılaştırmaların doğrulandığını

tespit etmişlerdir. Sonuçlar, eğitim verileri kapsamındaki ANFIS, ANFIS-TLBO ve ANFIS-SBO modellerinin AUROC değerlerinin sırasıyla 0,808, 0,785 ve 0,755 olduğunu, doğrulama veri seti ile ilgili olarak ANFIS-SBO modelinin AUROC değeri 0,781 ile daha yüksek olurken, ANFIS-TLBO ve ANFIS modellerinin AUROC değerleri sırasıyla 0,749 ve 0,681 olarak tespit edilmiştir. Ayrıca ANFIS-SBO modelinin doğrulama veri setinde daha düşük bir RMSE değeri göstermesi SBO algoritmasının daha iyi optimizasyon yeteneklerine sahip olduğunu gözlemlenmiştir. Aynı zamanda ANFIS-SBO modelinin işlem süresi ve yakınsaması ANFIS-TLBO modeline göre çok daha yüksek olduğu dolayısıyla bu makalede önerilen iki entegre model yeterli sonuçlar sağlayabilmekte olup, mükemmel doğruluğu ve verimliliği nedeniyle çalışma alanında heyecan duyarlılığı değerlendirmesi için en uygun model olarak ANFIS-SBO modeli olduğu sonucuna varmışlardır.

Genel Değerlendirme

ANFIS, eğitim verisi üzerinde oldukça düşük bir MSE (Ortalama Kare Hatası) ve RMSE (Karekök Ortalama Kare Hatası) değerleri göstermektedir. %70 eğitim verisiyle ANFIS'in MSE değeri 4.634.509,14 ve RMSE değeri 2.152,79'dur. Bu, modelin eğitim verisi üzerinde oldukça hassas ve doğru tahminler yapabildiğini göstermektedir. Aynı şekilde, MAE (Ortalama Mutlak Hata) değeri de YSA modeline kıyasla çok daha düşüktür (1.531,44), bu da ANFIS'in eğitim verisinde ortalama hata payının az olduğunu ortaya koyar.

YSA modeli, test verisi üzerinde ANFIS'e kıyasla daha iyi bir performans sergilemektedir. Örneğin, %30 test verisi ile YSA'nın MSE değeri 6.127.247,26 iken, ANFIS'te bu değer 6.878.691,17'dir. Bu, YSA'nın yeni ve görmediği veri üzerinde daha başarılı bir performans sergilediğini ve genelleme yeteneğinin daha güçlü olduğunu göstermektedir. YSA'nın test verisinde daha düşük bir hata oranına sahip olması, modelin dış veri setlerinde tahmin kabiliyetini artırdığı anlamına gelir.

ANFIS'in R^2 (Belirleme Katsayısı) değeri %70 eğitim verisi ile 0,817 olarak hesaplanmıştır. Bu oran, modelin eğitim verisinde oldukça güçlü bir tahmin doğruluğuna sahip olduğunu gösterir. Yüksek bir R^2 değeri, modelin değişkenler

arasındaki ilişkiyi iyi bir şekilde yakaladığını ve eğitim verisinde başarılı olduğunu kanıtlar.

YSA, %20 test verisiyle ANFIS'e kıyasla daha yüksek bir R^2 değerine sahiptir (0,781) Bu, modelin test verilerinde daha başarılı tahminler yaptığını ve dış verilerle daha yüksek bir doğruluk oranı yakaladığını gösterir. YSA'nın genelleme kabiliyetinin yüksek olması, modelin gerçek dünya verilerinde de güvenilir sonuçlar vereceğini kanıtlar.

ANFIS, eğitim verisi üzerinde özellikle %70 eğitim oranıyla oldukça başarılı sonuçlar verirken, %80 eğitim verisinde de nispeten güçlü bir performans göstermektedir. Eğitim oranı arttıkça performansın bir miktar azalması, modelin genelleme yeteneğini bir nebze sınırlandırır da, ANFIS'in eğitim süreci boyunca veriyle iyi bir uyum sağladığı ve hataları minimize ettiği açıktır.

Test verilerinde, YSA modeli daha düşük MAE ve RMSE değerlerine sahiptir. %30 test verisiyle YSA'nın RMSE değeri 2.475,33, MAE değeri ise 2.117,47'dir. Bu, modelin tahmin ettiği değerlerin gerçek değerlere daha yakın olduğunu ve ortalama hata miktarının daha düşük olduğunu gösterir. YSA'nın test verilerinde gösterdiği bu performans, modelin farklı veri setlerinde hatalarını düşük tutma eğiliminde olduğunu ortaya koymaktadır.

YSA, daha büyük veri setlerinde iyi performans gösterme potansiyeline sahip olup bu modelin esnekliğini ve geniş veri setlerinde öğrenme kapasitesini öne çıkarmaktadır. YSA'nın daha fazla veri ile daha iyi sonuçlar verebilme potansiyeli, özellikle büyük veri projelerinde büyük bir avantaj olduğu sonucuna varılmıştır. ANFIS'in düşük hata oranları ve yüksek tutarlılığı, modelin güvenilirliğini öne çıkarırken, YSA'nın esnekliği ve geniş veri setlerine adaptasyon yeteneği, modelin potansiyelini ortaya koyduğu sonucuna varılmış olup Şekil 9'da ANFIS ve YSA tahmininin gerçek değer karşılaştırma sonuçları gösterilmektedir.

Her iki modelin güçlü yönlerini göz önünde bulundurduğumuzda, ANFIS'in eğitim verilerinde daha başarılı bir performans sergilediğini, ancak YSA'nın test verilerinde genelleme yeteneğinin daha yüksek olduğunu söylemek mümkündür. ANFIS, eğitim sırasında verilerle daha iyi uyum sağlayarak daha doğru sonuçlar üretebilirken, YSA yeni verilerde (test verisinde) daha düşük hata oranlarına sahiptir

ve bu da onu genelleme açısından daha güçlü kılmaktadır. Tablo 5’de ANFİS ve YSA tahminlerinin yüzdesel sapmaları gösterilmektedir.

Modellerin belirli bir hata aralığı içinde, özellikle $\pm\%20$ limitleri içinde kalan tahminleri, modelin gerçek değerlere oldukça yakın tahminler üretebildiği tespit edilmiştir. Bu, modelin pratik uygulamalarda güvenilir olabileceği sonucuna varılmıştır.

Hem ANFİS hem de YSA modellerinin farklı eğitim verisi oranlarında (%70 ve %80) $\pm\%20$ limitleri içinde kalan tahminler üretebilmesi, bu modellerin esnek olduğunu ve farklı veri yapılarına uyum sağlayabildiğini göstermiştir. Bu, modelin farklı senaryolarda kullanılabilirliğini artıracak sonucuna varılmıştır.

Ayrıca tahminlerin kabul edilebilir bir hata payı içinde kalması, özellikle $\pm\%20$ limitleri içinde kalan tahminlerin, modelin güvenilir bir tahmin aracı olarak kullanılabileceğini tespit edilmiştir. Bu, gerçek dünya uygulamalarında bu modellerin kullanılabilirliğini artırdığı sonucuna varılmıştır.

Çalışmamızın analizlerinden elde edilen sonuçlara göre hangi modelin tercih edileceği, kullanıcı tercihlerine, modelin veri setiyle uyumluluğuna ve tahminleme gereksinimlerinin neler olacağına bağlı olarak kullanılabilirliğini ortaya çıkarmaktadır. Farklı alanlarda yapılacak olan çalışmalarda her iki model de sürekli olarak geri bildirim ve iyileştirilme çalışmaları ile daha iyi hale getirilebileceği düşünülmektedir.

KAYNAKÇA

- Acar, Ş.H. ve Kumru, P.Y. (2022). Kira bedellerinin yapay sinir ağı ve regresyon ile tahminlemesine yönelik çalışma. *Ahi Evran Akademi*, 3(1), 91-101.
- Acun, Ö. ve Apalı, A. (2020). Gri temelli maliyet tahmininin mobilya üretim sektöründe uygulanması. *Süleyman Demirel Üniversitesi Vizyoner Dergisi*, 11(Ek), 235-244.
- Ağraş, S. ve İnanoğlu, A. (2022). Üretim stratejilerinin belirlenmesinde rekabetçi güçlerin rolü. *Düzce Üniversitesi Sosyal Bilimler Dergisi*, 12(2), 697-716.
- Akbaş, M.Ç. (2022). Yapay sinir ağları tahminleme modeli ile hisse senedi fiyat endeksi tahminlemesi üzerine bir çalışma. *Antalya Bilim Üniversitesi Uluslararası Sosyal Bilimler Dergisi*, 3(2), 97-110.
- Akbulut, İ. ve Özcan, B. (2020). Hava kirliliği tahmini: yapay sinir ağları ve regresyon yöntemleriyle bir karşılaştırma. *Kocaeli Üniversitesi Fen Bilimleri Dergisi*, 3(1), 12-22.
- Alp, S. ve Nayir, B. (2019). Kalite uygulamaları dikkate alınarak gerçekleştirilen üretim planlama programının çok amaçlı programlama yöntemleri ile belirlenmesi. *Yalova Sosyal Bilimler Dergisi*, 9(18), 41-57.
- Altın, F.G. ve Çelik-Eroğlu, Ş. (2020). Gri tahmin ve box-jenkins yöntemleri ile Antalya Limanı için aylık konteyner talep tahmini. *Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7(3), 540-562.
- Apak, S. (2022). Pandemi döneminde yalın üretim uygulamalarının önceliklendirilmesi. *Endüstri Mühendisliği Dergisi*, 33(1), 62-74.
- Arslankaya, S. ve Öz, V. (2018). Time series analysis on sales quantity in an automotive company and estimation by artificial neural networks. *Sakarya University Journal of Science*, 22(5), 1482-1492.

- Aydın, A. (2022). Türkiye’de buğday üretim sektörünün yapısı ve arıma modeli ile üretim tahmini. *İşletme Ekonomi ve Yönetim Araştırmaları Dergisi*, 5(1), 1-18.
- Aydın, A. ve Dursun, C. (2022). Pazarlama ve üretim planlaması ilişkisi mobilya imalatçısı KOBİ’lere yönelik bir araştırma. *Karadeniz Araştırmaları Enstitüsü Dergisi*, 8(14), 9-23.
- Ayyıldız, E., Erdogan, M. ve Taskin, A. (2021). Forecasting covid-19 recovered cases with artificial neural networks to enable designing an effective blood supply chain. *Comput Biol Med.* 139(1), 2-20.
- Başak, E. E., Yılmaz, İ.S. ve Deniz, N. (2019). Endüstriyel ürün imalatı yapan bir işletmede yalın üretim uygulaması. *Endüstri Mühendisliği Dergisi*, 30(3), 157-172.
- Bayyurt, D.. ve Deveci-Kocakoç, İ. (2023). Yapay sinir ağları narx ile Türkiye fındık üretim miktarı tahmini. *Giresun Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 15-35.
- Bingöl, Ç. (2023). Yapay zekâ destekli uygulamalı eğitim platformu bankacılık simülasyonu. *Parion Akademik Bakış Dergisi*, 2(1), 1-22.
- Büyükarıkan, U. (2021). Hedef maliyetlemenin hidropnömatik kriko üretim işletmesinde uygulanması. *Abant Sosyal Bilimler Dergisi*, 21(3), 589-610.
- Calapoğlu, A., Şişeci-Çeşmeli, M., Pençe, İ. ve Çetinkaya-Bozkurt, Ö. (2021). Siparişe göre üretim yapan firmalarda sipariş sıralaması ve teslim tarihi problemi için bir karar modeli. *Acta Infologica*, 5(2), 341-357.
- Can, N. ve Şencan-Şahin, A. (2021). Yapay sinir ağları metodu ile günlük çiğ noktası sıcaklığı tahmini. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 11(4), 1154-1163.
- Can, Ş. (2021). Tıbbi ve aromatik bitki üretim miktarını etkileyen faktörlerin istatistik tekniklerle araştırılması ve üretim miktarının tahminlenmesi. *International Review Of Economics And Management*, 9(1), 80-92.

- Candan, G., Taşkin, M.T. ve Yazgan, H.R. (2014). Demand forecasting in pharmaceutical industry using artificial intelligence: neuro-fuzzy approach. *Journal of Military and Information Science*, 2(2), 41-49
- Cankurt, S. ve Subaşı, A. (2022). Tourism demand forecasting using stacking ensemble model with adaptive fuzzy combiner, soft computing in decision making and in modeling in economics. *Soft Computing*, 26, 3455–3467.
- Cansız, Ö.F., Erginer, İ. ve Doğru, E. (2021). Amerika’da meydana gelen trafik kazalarının yapay sinir ağları ve çok değişkenli regresyon yöntemleriyle tahmini. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 4(3), 342-354.
- Cansız, Ö.F., Öztekin, N. ve Erginer, İ. (2020). Optimum taşıt sayısının belirlenmesinde yapay sinir ağları ile çok değişkenli regresyon tekniklerinin karşılaştırılması. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 11(2), 771-782.
- Chen, W., Chen, X., Peng, J., Panahi, M. ve Lee, S. (2021). Landslide susceptibility modeling based on anfis with teaching-learning-based optimization and satin bowerbird optimizer. *Geoscience Frontiers, Contents lists available at Science Direct*, 12, 93-107.
- Cinel, E.A. ve Yolcu, U. (2021). Türkiye’de aylık işsizlik oranlarının yapay sinir ağları ile öngörüsü. *Yaşar Üniversitesi E-Dergisi*, 16(62), 492-508.
- Civelek, Ç. (2021). Yapay sinir ağları kullanarak Türkiye traktör satış adedinin tahmin edilmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 31(1), 375-381.
- Çınaroğlu, E. ve Avcı, T. (2020). THY hisse senedi değerinin yapay sinir ağları ile tahmini. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 34(1), 1-19.
- Çörekcioğlu, M., Ercan, E. ve Aras-Elibüyük, S. (2021). Yapay sinir ağı yöntemlerinin tekstil sektöründe kullanım uygulamaları. *Teknik Bilimler Dergisi*, 11(2), 14-20.
- Damla, Y., Temiz, T. ve Keskin, E. (2020). Yapay sinir ağı kullanılarak su seviyesinin tahmin edilmesi: Yalova Gökçe Barajı Örneği. *Kırklareli Üniversitesi Mühendislik ve Fen Bilimleri Dergisi*, 6(1), 32-49.

- Dedeoglu, T. ve Çetin, O. (2021). Sağlık sektöründe hasta talebinin tahmini. *Trakya Üniversitesi İktisadi ve İdari Bilimler Fakültesi E-Dergi*, 10(1), 25-38.
- Demircan Keskin, F. ve Soyuer, H. (2022). Bir çimento firmasında istatistiksel zaman serileri yöntemleri ve derin öğrenme ile talep tahminleme. *Avrupa Bilim ve Teknoloji Dergisi*, 36(1), 15-20.
- Dinç, N. ve Ulukavak, M. (2022). Adıyaman ili için yapay sinir ağları ile geoit belirleme. *Harran Üniversitesi Mühendislik Dergisi*, 7(3), 181-192.
- Doğan, O. (2016). Uyarlamalı sinirsel bulanık çıkarım sisteminin (anfis) talep tahmini için kullanımı ve bir uygulama. *Dokuz Eylül Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Dergisi*, 31(1), 257-288.
- Dulkadir, B. (2021). Bilişim teknolojisi tabanlı karar destek sistemleri ile iplik üretim tesislerinde üretimin planlanması. *Alanya Akademik Bakış*, 5(1), 193-209.
- Erginer, İ., Erginer, M. ve Cansız, Ö.F. (2020). Trafik kaza sayısının ve yaralı sayısının yapay sinir ağları ile tahmini. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 3(1), 29-35.
- Eroğlu, A. ve Tatar, E. (2023). An economic production quantity model with defective production. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 28(3), 401-411.
- Erol, M. ve Eken, E.N. (2020). Ekonomik kriz dönemlerinde tam zamanında üretim (just in time) sisteminin uygulanması. *R&S - Research Studies Anatolia Journal*, 3(1), 63-69.
- Erozan, İ. ve Müminoğlu, M. (2020). Bir otomobil yan sanayi tedarikçisinde dünya klasında üretim uygulaması. *Endüstri Mühendisliği Dergisi*, 31(3), 251-266.
- Ersöz, T., Sarız, K. ve Ersöz, F. (2020). Demir-çelik üretim hattında yalın üretim. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 8(1), 801-826.
- Ertaylan, A., Aktaş, Ö. ve Doğan, Y. (2021). Yapay sinir ağları ile piyasa takas fiyatı tahminlemesi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 23(67), 93-105.

- Eşidir, K.A., Gür, Y.E., Yoğunlu, V. ve Çubuk, M. (2022). Yapay sinir ağları (YSA) ve arıma modelleri ile Türkiye’de aylık sıfır km otomobil satış adetlerinin tahmin edilmesi. *Pamukkale Üniversitesi İşletme Araştırmaları Dergisi*, 9(2), 260-277.
- Eyitmiş, A. ve Bilginer, R. (2021). Üretim teknolojilerinin verimlilik karşılaştırılması; alüminyum levha imalat uygulaması. *Kahramanmaraş Sütçü İmam Üniversitesi Sosyal Bilimler Dergisi*, 18(2), 1204-1217.
- Gonzalez del Cerro, R.T., Subathra, M.S.P., Kumarc, N.M., Verrastro, S. ve George, S.T. (2021). Modelling the daily reference evapotranspiration in semi-arid region of south India: a case study comparing anfis and empirical models. *Information Processing in Agriculture*, 8(1) 173–184.
- Gökçe, B. ve Sonugür, G. (2016). Anfis ve YSA yöntemleri ile işlenmiş doğal taş üretim sürecinde verimlilik analizi. *Afyon Kocatepe University Journal of Science and Engineering*, 16(1), 174-185.
- Güner, Ş.N. ve Demir, H.U. (2022). Yapay sinir ağları ve zaman serileri yöntemi ile demir çelik ithalatı tahmini. *Sakarya İktisat Dergisi*, 11(3), 389-397.
- Güven, İ. ve Şimşir, F. (2020). Demand forecasting with color parameter in retail apparel industry using artificial neural networks (ann) and support vector machines (svm) methods. *Computers & Industrial Engineering, Contents lists available at Science Direct*, 147(1), 106678.
- Harman, G. (2022). Altın dolar paritesinin farklı yapay sinir ağları öğrenme algoritmaları kullanarak bir sonraki kur tahmini. *Veri Bilimi Dergisi*, 5(1), 1-12.
- Hasköse, A. (2020). Lead time management for production planning in job shops. *Erciyes Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 48(1), 179-195.
- Işık, H. ve Şeker, M. (2021). *Yapay Sinir Ağı (YSA) kullanarak farklı kaynaklardan Türkiye’de elektrik enerjisi üretim potansiyelinin tahmini*. Computer Science, Idap-2021: 5th International Artificial Intelligence and Data Processing Symposium (Special), 304-311.

- İlhan, A.T. ve Öz, S. (2020). Yapay sinir ağlarının gayrimenkullerin toplu değerlemesinde uygulanabilirliği: Gölbaşı İlçesi örneği, *Hacettepe Üniversitesi Sosyal Bilimler Dergisi*, 2(2), 160-188.
- İnan, T. ve Baba, A.F. (2020). Estimating wind speed using artificial neural networks and anfis methods (measuring buoy example). *Global Journal of Information Technology: Emerging Technologies*, 8(2), 55-61.
- Kahraman, O. (2021). Tasarruf kavramının üretim sürecindeki anatomisi üzerine bir analiz. *Çalışma ve Toplum Dergisi*, 1(68), 415-426.
- Kalaycı D.E. (2020). Anfis ile doğalgaz talep tahmini; Türkiye örneği, *USBAD Uluslararası Sosyal Bilimler Akademi Dergisi*, 2(3), 495-511,
- Kamber, E., Körpüz, S., Can, M. ve Yumurtacı-Aydoğmuş, H. (2021). Yapay sinir ağlarına dayalı kısa dönemli elektrik yükü tahmini. *Endüstri Mühendisliği Dergisi*, 32(2), 364-379.
- Kantar, L. (2020). BİST 100 endeksinin yapay sinir ağları ve arma modeli ile tahmini. *Muhasebe ve Finans İncelemeleri Dergisi*, 3(2), 121-131.
- Kara, S. ve Özcan, P. (2020). Muhasebe manipülasyonlarında yapay sinir ağlarının önemi ve bir uygulama. *Muhasebe ve Denetime Bakış*, 20(60), 155-176.
- Karabacak, T. ve Uzundumlu, A. (2020). Kayısı üretiminde önde gelen illerin 2019-2025 üretim tahminleri. *IBAD Sosyal Bilimler Dergisi*, 1(1), 561-573.
- Karakoç, M. ve Dardanoğlu, E. (2020). Kaynak tüketim muhasebesi: seramik üretim işletmesinde bir uygulama. *Muhasebe ve Finansman Dergisi*, 88(1), 39-56.
- Kaya, A., Kaya, G. ve Çebi, F. (2022). Forecasting automobile sales in Turkey with artificial neural networks. *International Journal of Business Analytics*, 6(4), 50-60.
- Khan, M.A. ve Algarni, F. (2020). A healthcare monitoring system for the diagnosis of heart disease in the iomt cloud environment using mssso-anfis. *Digital Object Identifier, IEEE Access*, 8(1), 122259-122269.

- Kılıç, F., Aka, H. ve Aktuğ, Z.B. (2020). Futbolda yapay sinir ağları modeli ile lig sıralaması tahmini. *Uluslararası Güncel Eğitim Araştırmaları Dergisi*, 6(2), 379-391.
- Kıral, G. ve Çelik, C. (2020). Panel verileri ile Türkiye’de konut fiyatlarını etkileyen faktörlerin tespiti ve yapay sinir ağları yaklaşımı. *Çankırı Karatekin Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 11(2), 1-21.
- Konuk, A., Aksoy, M. ve Ak, H. (2021). Çoklu bağlantı durumunda kentleşme göstergelerinden agrega üretim miktarının tahmini. *Scientific Mining Journal*, 60(2), 97-106.
- Korkmaz, G. (2020). Yapay zekâ yöntemleriyle sınıflandırma ve finans sektöründe bir uygulama. *Akademik Yaklaşımlar Dergisi*, 11(2), 91-109.
- Koruca, H.İ. ve Kocaer, E.R. (2019). Otomatik üretim sistemlerinde verimlilik analizi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 7(4), 897-905.
- Kurt, A.S. (2022). Türkiye ekonomisi için ihracat ve ithalatın yapay sinir ağları ile tahmini. *Fiscaoeconomia*, 6(2), 808-822.
- Kurtlar, M. ve Atış, C. (2022). Zaman etkenli faaliyet tabanlı maliyet saptama: bir halı üretim işletmesinde uygulama. *Muhasebe ve Finans İncelemeleri Dergisi*, 5(2), 173-192.
- Kuşcuoğlu, M.Ö. ve Dilik, T. (2023). Sipariş tipi üretim yapan orta ölçekli mobilya işletmelerinde makine seçimi. *Mobilya ve Ahşap Malzeme Araştırmaları Dergisi*, 6(1), 80-89.
- Lawal, A.I., Kwona, S., Hammed, O.S. ve Idris, M.A. (2021). Blast-induced ground vibration prediction in granite quarries: An application of gene expression programming, anfis, and sine cosine algorithm optimized ann. *International Journal of Mining Science and Technology, Contents Lists Available at Sciencedirect*, 31(1), 265–277.
- Mousazadeh, F., Naeem, M.H.T., Daneshfar, R., Soulgani, B.S. ve Naseri, M. (2021). Predicting the condensate viscosity near the wellbore by elm and anfis-pso strategies. *Journal of Petroleum Science and Engineering, Contents lists available at ScienceDirect*, 204(1), 2-8.

- Okwu, M.O., Tartibua, L.K., Ojoc, E.O., Adumed, S., Gidiagbaa, J.O. ve Fadeyie, J. (2023). Anfis model for cost analysis in a dual source multi-destination system. *Procedia Computer Science*, 217(1), 1266–1279.
- Öncül, M. ve Ateş, V. (2020). İşletmelerin akıllı üretim modeline geçiş sürecinde karşılaştıkları sorunların belirlenmesi. *Organizasyon ve Yönetim Bilimleri Dergisi*, 12(2), 116-132.
- Önen, V. (2020). Arıma yöntemiyle Türkiye'nin hava yolu kargo talep tahmin modellemesi ve öngörüsü. *Journal Of Management And Economics Research*, 18(4), 29-53.
- Özgür, A. S., Tarhan, Ç., Komesli, M. ve Tecim, V. (2023). Yapay zekâ teknikleri kullanılarak proje üretim sistemlerinin tasarımı ve geliştirilmesi. *Journal Of Information Systems and Management Research*, 5(1), 1-12.
- Özkan, S. ve Bulut, Ö. (2020). Hazırlık maliyetli stoğa-üretim sistemlerinin kontrolü. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35(3), 1199-1212.
- Özmen-Akyol, S. ve Gülbandılar, E. (2019). Prediction of iris flower type with ann methods and anfis. *Journal of ESTUDAM Information*, 1(1), 5-11.
- Öztürk, K. ve Şahin, M.E. (2018). Yapay sinir ağları ve yapay zekâyâ genel bir bakış. Recep Tayyip Erdoğan Üniversitesi, *Mühendislik Fakültesi, Takvim-i Vekayi*, 6(2), 25-36.
- Öztürk, S.E. ve Şahin, S. (2021). Otomotiv ve tekstil sektöründe regresyon ve zaman serilerine yönelik çalışmalar: bir alan yazın taraması. *Abant Sosyal Bilimler Dergisi*, 21(2), 119-142.
- Reşat, H.G. (2020). Sürdürülebilir enerji yönetimi için yapay sinir ağları ve arıma metotları kullanılarak melez tahmin modelinin tasarlanması ve geliştirilmesi: tütün endüstrisinde vaka çalışması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35(3), 1129-1140.
- Saka-İlgın, K. ve Sarı, S. (2022). Bist-100 endeks hareketlerinin BRICS endeksleri aracılığıyla tahmin edilmesi: yapay sinir ağları uygulaması. *Abant Sosyal Bilimler Dergisi*, 22(1), 350-366.

- Sarı, S.S. (2022). Finansal stres endeksinin dalgacık dönüşümlü yapay sinir ağları kullanılarak tahmin edilmesi. *The Journal of International Scientific Researches*, 7(3), 282-296.
- Sarıkaya, H.A., Soydemir, E.K., Sardaş, B. ve Çayır-Ervural, B. (2022). Bisküvi üretim hatlarında hazırlık sürelerinin azaltılmasına yönelik yalın üretim ve smed uygulaması. *Endüstri Mühendisliği Dergisi*, 33(2), 413-439.
- Sarkar, J., Prottoy, Z. H., Bari, T. ve Faruque, A. A. (2021). Comparison of anfis and ann modeling for predicting the water absorption behavior of polyurethane treated polyester fabric. *Heliyon Contents lists available at ScienceDirect Journal*, 7(9), 17-15.
- Sarr, M.P., Thiam, A. ve Dieng, B. (2023). Anfis and ann models to predict heliostat tracking errors. *Heliyon Contents lists available at Science Direct Journal*, 9(1), 2-14.
- Savcı, M. (2019). Tam zamanlı üretim sisteminin üretim giderlerine etkisi: çay işletmesi örneği. *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(19), 290-309.
- Savsar, M. ve Çiçek, H. (2021). Analysis and improvement of production planning processes in a food factory. *Avrupa Bilim ve Teknoloji Dergisi*, 29(1), 377-386.
- Sel, A., Zengin, N. ve Yıldız, Z. (2020). Alternatif yatırım araçları ile bitcoin fiyatları arasındaki ilişkinin yapay sinir ağı ile tahmini. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 21(2), 157-169.
- Sorrosal, G., Irigoyen E., Borges C.E., Martin C., Macarulla A.M. ve Alonso-Vicario A. (2017). Artificial neural network modelling of the bioethanol-to-olefins process on a HZSM-5 catalyst treated with alkali. *Appl. Soft Comput. J. Sep.* 58(1), 648–656.
- Söylemez, Y. (2020). Çok katmanlı yapay sinir ağları yöntemi ile altın fiyatlarının tahmini. *Sosyoekonomi*, 28(46), 271-291.

- Sundar, L.S., Deepanraj, B. ve Mewada, H.K. (2023). ANFIS based effectiveness and number of transfer units predictions of MWCNT/water nanofluids flow in a double pipe U-bend heat exchanger. *Case Studies in Thermal Engineering*, 43(1), 102-110.
- Süleymanlı, C. (2021). Yapay sinir ağları ile Türkiye'nin brüt döviz rezervlerinin tahmini. *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 6(4), 612-624.
- Şahan, S. ve Altınbay, A. (2023). Yalın üretim sistemi ve bir uygulama örneği. *Gümrük ve Ticaret Dergisi*, 10(34), 21-39.
- Şahin, M. ve Erol, R. (2018). Prediction of attendance demand in european football games: comparison of anfis, fuzzy logic, and ann. *Computational Intelligence and Neuroscience*, 1(1)1-14.
- Şahin, S. ve Eren, D. (2022). Turizm ve sağlık turizminde talep tahmini çalışmaları: bir alan yazın taraması. *Uluslararası Batı Karadeniz Sosyal ve Beşeri Bilimler Dergisi*, 6(2), 191-216.
- Şenol, D. ve Denizhan, B. (2023). Kripto para değerinin yapay sinir ağları ile tahmini. *Endüstri Mühendisliği Dergisi*, 34(1), 42-69.
- Tekin, T.G. (2023). Geniş ekonomik grupların ihracat değerinin yapay sinir ağları yöntemiyle tahminlenmesi. *Ekev Akademi Dergisi*, 9(1), 319-335.
- Patır, S. ve Tekin, T.G., (2023). Amerikan doları kurunun yapay sinir ağları yöntemiyle tahminlenmesi: 2009 – 2021 dönemi. *R&S - Research Studies Anatolia Journal*, 6(1), 56-77.
- Terzioğlu, E. ve Şahin, S. (2022). Perakende sektöründe talep tahmin çalışmaları: alanyazın taraması. *Düzce Üniversitesi Sosyal Bilimler Dergisi*, 12(2), 584-596.
- Tuvay, N.H. ve Ermetin, O. (2023). Yapay zekâ teknolojilerinin hayvancılıkta kullanımı. *Hayvansal Üretim Dergisi*, 64(1), 48-58.
- Türk, E. ve Kıranı, F. (2019). Yapay sinir ağları ile talep tahmini yapma: beyaz eşya üretim planlaması için ysa uygulaması. *Journal of Istanbul Sabahattin Zaim University, Natural Sciences Institute*, 1(1), 30-37.

- Tüzüntürk, S. ve Sert Eteman, F. (2023). Türkiye iç piyasasında ulusal çimento talebinin yapay sinir ağları ile tahmini. *Maliye ve Finans Yazıları*, 120(1), 131-154.
- Urgan, N.N. ve Tamgöz, M. (2020). Yapay sinir ağları ile aktif kullanıcı sayısı tahmini üzerine bir uygulama. *European Journal of Engineering and Applied Sciences*, 3(2), 8-14.
- Ülker, M.A. (2021). Elektrik talep-üretim süreklilik eğrileri yardımı ile tahmini elektrik üretim maliyeti hesabı - bir örnek durum çalışması. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 8(15), 584-594.
- Vural, D. (2019). *Türkiye’de perakende sektöründe elektronik ürünlere olan talebin yapay sinir ağı ile modellenmesi*. [Yüksek Lisans Tezi] İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı.
- Wong, Y.J., Arumugasamy, S.K., Chung, C.H., Selvarajoo, A. ve Sethu, V. (2020). comparative study of artificial neural network (ann), adaptive neuro-fuzzy inference system (anfis) and multiple linear regression (mlr) for modeling of cu (II) adsorption from aqueous solution using biochar derived from rambutan (nephelium lappaceum) peel. *Environ Monit Assess*, 192(7), 2-20.
- Yabar, E. ve Aydın, M.C. (2020). Dalgacık dönüşümlü yapay sinir ağlarıyla günlük akım serilerinin tahmini. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(2), 943-951.
- Yalçın, Ö.F. (2020). Basit mesnetli köprülerde hareketli yük dağılım faktörleri denklemlerinin yapay sinir ağları ile elde edilmesi. *Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 35(3), 609-622.
- Yaman, B. ve Akgül, Y. (2020). Türkiye’nin ihracat değerlerinin yapay sinir ağları ile tahmini üzerine bir inceleme. *Nicel Bilimler Dergisi*, 2(2), 29-42.
- Yarat, S. ve Orman, Z. (2023). Elektrik güç dağıtımında akıllı sayaç verileri için anomali tespiti ve tahminleme. *Bilgisayar Bilimleri ve Teknolojileri Dergisi*, 3(2), 72-85.

- Yerlikaya, M.A. ve Arıkan, F. (2022). Sipariş toplama sistemlerinde üretim planlama ve sınıf temelli depo ürün atama problemi için bütünleşik model önerisi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37(3), 1703-1712.
- Yıldırım, H. ve Karaatlı, M. (2022). Yapay sinir ağları narx modeli ile elma üretim miktarının öngörülmesi. *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 42(1), 1-29.
- Yıldız, R. (2021). Linyitin yıllık üretim miktarının zaman serisi analizleri ile değerlendirilmesi. *Parion Akademik Bakış Dergisi*, 1(2), 157-171.
- Yılmaz, S. ve Kılıcı, S.B. (2020). İleri sürümlü yapay sinir ağları eğitim ve geliştirme aracı tasarımı. *Kocaeli Üniversitesi Fen Bilimleri Dergisi*, 3(1), 133-146.
- Yılmaz, Ş.H. ve Özcan, B. (2020). Yapay sinir ağı ve regresyon ile satın alma gücü paritesine göre kişi başı gayrisafı yurt içi hasıla tahmini. *Uluslararası Sosyal Bilimler Akademi Dergisi*, 3(1), 57-72.
- Yiğit, V. ve Aslan, P.M. (2020). Çimento fabrikası üretim hattının simülasyonla incelenmesi. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 24(4), 1721-1734.
- Yüce, T. ve Kabak, M. (2021). Makine öğrenmesi algoritmaları ile detay üretim alanları için iş merkezi kırılimında üretim süresi tahminleme. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, 37(1), 47-60.
- Yücel, Ö. (2020). Konfeksiyon işletmelerinde üretim süreç etkinliklerinin belirlenmesi. *Turkish Journal of Fashion Design and Management*, 2(1), 11-19.
- Yürük, M.F. (2021). Yapay sinir ağları ile hisse senedi fiyat tahmin modeli: Türk Hava Yolları uygulaması. *Journal of Aviation*, 5(2), 282-289.
- Zainuddin, N.H., Ju, Y., Chen, Z., Liu, F. ve Fang, X. (2019). Improvement of time forecasting models using a novel hybridization of bootstrap and double bootstrap artificial neural networks. *Appl. Soft Comput. J. Nov.* 84(1), 2-19.

- Zanganeh, M. (2020). Improvement of the anfis-based wave predictor models by the particle swarm optimization. *Journal of Ocean Engineering and Science*, T(1), 84–99.
- Zhu, E., Ju, Y., Chen, Z., Liu, F. ve Fang, X. (2020). Dtof-ann: an artificial neural network phishing detection model based on decision tree and optimal features. *Applied Soft Computing Journal*. 95(1), 2-14.

