



T.C.

SELÇUK ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

YÖNETİM BİLİŞİM SİSTEMLERİ ANA BİLİM DALI

YÖNETİM BİLİŞİM SİSTEMLERİ BİLİM DALI



TEDARİK ZİNCİRİNDE VERİ MADENCİLİĞİ UYGULAMASININ
ARAŞTIRILMASI

INVESTIGATING THE APPLICATION OF DATA MINING IN THE
SUPPLY CHAIN

Şeydanur KOÇAK

YÜKSEK LİSANS TEZİ

Danışman

Doç. Dr. Hüseyin KOÇARSLAN

Konya- 2024

Bu çalışma, 06/11/2024 tarihinde ařağıdaki jüri tarafından Yönetim Biliřim Sistemleri Anabilim Dalı Yönetim Biliřim Sistemleri Bilim Dalı Programında Yüksek Lisans Tezi olarak kabul edilmiřtir.

**Savunma
Tez Jürisi**

Hüseyin KOÇARSLAN (Danıřman Adı ve Soyadı)
Selçuk Üniversitesi
İřletme Fakültesi

İlknur Çevik TEKİN (Üye Adı ve Soyadı)

Sedat KORKMAZ. (Üye Adı ve
Soyadı)

Selçuk Üniversitesi
İřletme Fakültesi

Konya Teknik Üniversitesi
Mühendislik ve Doęa Bilimleri Fakültesi

Teşekkür

Tez çalışmam sürecinde desteklerini ve yardımlarını esirgemeyen, akademik bilgisiyle yanımda olan değerli danışman hocam, sayın Hüseyin KOÇARSLAN'a en içten dileklerle teşekkür eder, saygılarımı sunarım.

Bu süreçte yardımlarını ve desteklerini esirgemeyen değerli Erhan KILINÇ hocama teşekkürü bir borç bilirim ve saygılarımı sunarım.

Bugünlere gelmem için bana sürekli destek çıkan ve okumamız için en büyük desteği sağlayan babam İrfan KOÇAK'a ve sevgili annem Gülseren KOÇAK'a teşekkür eder, sonsuz saygılarımı sunarım. Yine bu süreçte yanımda olan ablam Gülfiraz KOÇAK ve abim Ahmet KOÇAK'a teşekkür eder, saygılarımı sunarım.

Şeydanur KOÇAK



SELÇUK ÜNİVERSİTESİ
Sosyal Bilimler Enstitüsü Müdürlüğü



Öğrencinin

Adı Soyadı	Şeydanur KOÇAK
Numarası	214271001004
Ana Bilim / Bilim Dalı	Yönetim Bilişim Sistemleri / Yönetim Bilişim Sistemleri
Programı	Yüksek Lisans
Tez Danışmanı	Doç. Dr. Hüseyin KOÇARSLAN
Tezin Adı	Tedarik Zincirinde Veri Madenciliği Uygulamasının Araştırılması

ÖZET

Tedarik zinciri işletmelerin doğru zamanda, doğru ürün ve hizmetleri müşteriye en hızlı ve en güvenli bir şekilde ulaştırmak için her geçen gün gelişmekte olan teknolojiye dayanmaktadır. Bu gelişmeyle, var olan tüm süreçler tedarik zincirine entegre edilerek birçok veri akışının sürekliliğini sağlamaktadır. Tedarik zinciri bu veriler ile tüm faaliyetleri analiz ederek daha verimli sonuçlar almaktadır. Bu sonuçlar doğrultusunda işletmeler maliyetlerini optimize etmektedirler. Bu nedenle, tedarik zincirinde veri madenciliğinin kullanılması lojistik, depolama, üretim, stok, sipariş ve envanter gibi iş süreçlerinin daha aktif olması için gerçek zamanlı veriler kullanılmaktadır. Bu veriler ile işletmeler daha hızlı kararlar alarak tedarik zincirinin verimliliğini arttırmaktadırlar. Bu verimlilik müşteri memnuniyetini artırarak daha fazla kar elde edilmesini sağlamaktadır. Bu durum tedarik zincirinde rekabet avantajının sürekliliğini devam ettirmektedir. Bu çalışmanın amacı tedarik zincirindeki verileri kullanarak işletmelerin tahminler yapabilmesini sağlayarak faaliyetlerini nasıl planlamaları gerektiğini sağlamaktır. Bu kapsamda Kaggle veri tabanından temin edilen tedarik zincirinde araba satışı veri seti kullanılmıştır. Bu veri seti içerisinde 23906 adet gözlem verisi yer almaktadır. Değişken özellik sayısı toplamda 16'dır. Veri setinin doğru tahminler yapabilmesine yardımcı olması için WEKA programında analizler yapılmıştır. Bu analizlerin sonuçlarını almak için Decision Tree (J48), Bayes Net, Naive Bayes, KNN, LWL, Bagging ve Adaboost M1 algoritmaları ile sınıflandırma yapılarak bilgiler sunulmaktadır.

Anahtar kelime: Tedarik Zinciri, Veri Madenciliği, Sınıflandırma Algoritmaları



SELÇUK ÜNİVERSİTESİ
Sosyal Bilimler Enstitüsü Müdürlüğü



Öğrencinin

Adı Soyadı	Şeydanur KOÇAK
Numarası	214271001004
Ana Bilim / Bilim Dalı	Yönetim Bilişim Sistemleri / Yönetim Bilişim Sistemleri
Programı	Yüksek Lisans
Tez Danışmanı	Doç. Dr. Hüseyin KOÇARSLAN
Tezin Adı	Investigating The Application Of Data Mining In The Supply Chain

ABSTRACT

Supply chain businesses benefit from the technology that is developing day by day in order to deliver the right products and services to the customer at the right time in the fastest and safest way. With this development, the supply chain integrates all existing processes and ensures the continuity of many data flows. The supply chain gets more efficient results by analyzing all activities with this data. In line with these results, businesses optimize their costs. Therefore, the use of data mining in the supply chain uses real-time data to make business processes such as logistics, storage, production, stock, order and inventory more active. With this data, businesses make faster decisions and increase the efficiency of the supply chain. This efficiency increases customer satisfaction and leads to more profit. This situation maintains the continuity of competitive advantage in the supply chain. The aim of this study is to enable businesses to make forecasts by using the data in the supply chain and how they should plan their activities. In this context, the data set of car sales in the supply chain obtained from the Kaggle database was used. There are 23906 observation data in this dataset. The number of variable features is 16 in total. Analyses were performed in the WEKA program to help the dataset make accurate predictions. In order to get the results of these analyzes, information is presented by classifying with Decision Tree (J48), Bayes Net, Naive Bayes, KNN, LWL, Bagging and Adaboost M1 algorithms.

Keyword: Supply Chain, Data Mining, Classification Algorithms

İÇİNDEKİLER

Teşekkür.....	i
ÖZET.....	ii
ABSTRACT.....	iii
TABLolar LİSTESİ.....	viii
ŞEKİLLER LİSTESİ.....	viii
Kısaltmalar	ixx
Giriş	1
BİRİNCİ BÖLÜM TEDARİK ZİNCİRİ KAVRAMI NEDİR?	2
1. 1. Tedarik Zincirinin Fonksiyonları	17
1.1.1. Tedarik Fonksiyonu	18
1.1.2. Üretim Fonksiyonu.....	19
1.1.3. Planlama Fonksiyonu.....	21
1.1.4. Sipariş Fonksiyonu	22
1.1.5. Stok Yönetimi Fonksiyonu	23
1.1.6. Depolama Fonksiyonu.....	24
1.1.7. Envanter Fonksiyonu	25
1.1.8. Dağıtım Fonksiyonu	26
1.1.9. Müşteri Hizmetleri	27
İKİNCİ BÖLÜM VERİ MADENCİLİĞİ NEDİR?	28
2.1. Veri Madenciliğinin Teknikleri	37
2.1.1 İstatistikler.....	38
2.1.2. Sınıflandırma.....	39
2.1.3. Kümeleme	40
2.1.4. Modelleme.....	41
2.1.5. Karar Ağaçları	42
2.1.6. Yapay Sinir Ağları	44

2.2. Tedarik Zincirinde Veri Madenciliği.....	45
ÜÇÜNCÜ BÖLÜM WEKA PROGRAMI	47
LİTERATÜR TARAMASI	53
DÖRDÜNCÜ BÖLÜM ARAŞTIRMANIN METODOLOJİSİ	56
4.1. Araştırmanın Konusu.....	56
4.2. Önemi.....	56
4.3. Amaç	56
4.4. Sınırlılıklar	57
4.5. Yöntem.....	57
4.6. Kullanılan Sınıflandırma Algoritmaları.....	57
4.6.1. Decision Tree (J48).....	57
4.6.2. Naive Bayes.....	58
4.6.3 LWL (Locally Weighted Learning- Yerel Ağırlıklı Öğrenme).....	59
4.6.4. IBk (K-en yakın komşu, k-nearest neighbour).....	60
4.6.5. Bagging.....	62
4.6.6. Adaboost M1.....	63
4.7. Performans Ölçümleri.....	63
4.7.1 Kappa İstatistiği	63
4.7.2. Karmaşıklık matrisi (Confussion Matrix)	64
4.8. Çapraz Doğrulama	67
4.9. Veri Seti	68
4.9.1. Veri Ön İşleme.....	69
4.9.2. Veri temizleme ve düzenleme.....	69
4.9.3. Veri Tipi Dönüşümü	70
4.10. Araştırma Bulguları	71
4.10.1. Sınıflandırma Algoritmaları ve Değerlendirmeler	72
4.10.1.1. D1. Decision Tree (J48) Sonuçları	72

4.10.1.2. D1. Naive Bayes Sonuçları.....	74
4.10.1.3. D1. k-en Yakın Komşu Algoritması Sonuçları	75
4.10.1.4. D1. LWL (Locally Weighted Learning- Yerel Ağırlıklı Öğrenme) Algoritması Sonuçları	77
4.10.1.5. D1. Adaboost M1 Sonuçları.....	78
4.10.1.6. D1. Bagging Sonuçları.....	80
4.10.1.7. D2 Veri Seti Model Sonuçları.....	82
Tartışma ve Sonuç.....	88
Öneriler	91
Kaynakça.....	92

TABLolar LİSTESİ

Tablo-1: Kappa katsayı değeri aralıklarına göre yorumlama tablosu	64
Tablo-2: Karmaşıklık matrisi (Confusion Matrix)	65
Tablo-3: Çok Sınıflı Sınıflandırma İçin Performans Ölçüm Metriği ve Hesaplama Formülleri	66
Tablo-4: Decision Tree (J48) Algoritması Karmaşıklık Matrisi	73
Tablo-5:Decision Tree (J48) Algoritması Performans Sonuçları	73
Tablo-6: Naive Bayes Algoritması Karmaşıklık Matrisi	74
Tablo-7: Naive Bayes Algoritması Karmaşıklık Matrisi	75
Tablo-8: k-en Yakın Komşu Algoritması Karmaşıklık Matrisi	76
Tablo 9: k-en Yakın Komşu Algoritması Performans Sonuçları	76
Tablo-10:LWL Algoritması Karmaşıklık Matrisi	77
Tablo-11:LWL Algoritması Performans Sonuçları	78
Tablo-12: Adaboost M1 Algoritması Karmaşıklık Matrisi	79
Tablo-13: Adaboost M1 Algoritması Performans Sonuçları	79
Tablo-14: Bagging Algoritması Karmaşıklık Matrisi	80
Tablo-15: Bagging Algoritması Performans Sonuçları	81
Tablo-16: D2 Modeli Matris ve Performans Metrikleri	82
Tablo-17: Literatürde Kullanılan Algoritmaların Başarı Performansları	88

ŞEKİLLER LİSTESİ

Şekil-1: Tedarik Zincirinin Yapısı.....	2
Şekil-2: Tedarik Zinciri Yapısı	3
Şekil-3: Etkileşimli Tedarik Zinciri.....	4
Şekil-4: Tedarik Zinciri	5
Şekil-5: Tedarik zincirinde ürün akışı	11
Şekil-6: Tek safhalı tedarik zinciri	12
Şekil-7: Çok Safhalı Tedarik Zinciri	13
Şekil-8: Veri madenciliği ve disiplinler	28
Şekil-9: Veri madenciliğinin veri işleme süreci içindeki yeri	29
Şekil-10: Veri Madenciliği Süreci	34
Şekil-11: Sınıflandırma Süreci	40
Şekil-12: Kümeleme Yöntemleri	41
Şekil-13: Örnek Karar Ağacı Yapısı	43
Şekil-14: Yapay Sinir Ağı	44
Şekil-15: WEKA Önyüz.....	48
Şekil-16: WEKA Program Menüsü	49
Şekil-17: WEKA Visualization Menüsü	50
Şekil-18: WEKA Tools Menüsü	51
Şekil-19: WEKA Help Menüsü	51
Şekil 20: k-en yakın komşu algoritması örneği	61
Şekil-21: Çapraz Doğrulama (k-Fold Cross validation).....	68
Şekil-22: D1 Veri Seti Sınıflandırma Algoritmaları Başarı Oranı Sonuçları.....	81
Şekil-23: D2 Veri Seti İçin Sınıflandırma Algoritmaları Başarı Oranı Sonuçları	87

Kısaltmalar

IBM: International Business Machines (Uluslararası İş Makineleri)

SPSS: Statistical Package for the Social Sciences (Sosyal Bilimler için İstatistik Programı)

SAS: Statistical Analysis System (İstatiksel Analiz Sistemi)

SQL: Structured Query Language (Yapılandırılmış Sorgu Dili)

DB: Database (Veri tabanı)

KNIME: Konstanz Information Miner (Konstanz Bilgi Madencisi)

ROC: Receiver Operating Characteristic (Alıcı İşlem Karakteristikleri)

AUC: Area Under the Curve (Eğri Altında Kalan Alan)

DBSCAN: Density Based Spatial Clustering of Applications with Noise (Gürültülü Uygulamaların Yoğunluk Tabanlı Uzamsal Kümelenmesi)

YSA: Yapay Sinir Ağları

ASCII: American Standard Code for Information Interchange (Bilgi Değişimi İçin Amerikan Standart Kodlama Sistemi)

Giriş

Günümüzde işletmeler hızla gelişen ve büyüyen teknolojiyi kullanarak rekabet avantajı sağlamaktadır. Bu avantajın sürdürülebilir olması için etkin bir şekilde verileri kullanmaları gerekmektedir. Verilerin sağlamış olduğu bilgiler ile işletmeler daha uzun vadeli planlamalar yaparak tedarik zincirinde daha verimli yol almaktadırlar. Tedarik zincirinde kullanılan sistemlerdeki verilerin veri tabanlarından çekilerek yorumlanabilir ve analiz edilebilir duruma dönüştürülerek kullanılması gerekmektedir. Bu sayede veriler ile tedarik zincirindeki sistemler hakkında bilgiler edinilerek planlamaların yapılması sağlanmaktadır.

Tedarik zincirinin sürdürülebilmesi için aktif pazarlardaki değişikliklerinin algılanarak satışlardaki karların arttırılmasına yönelik doğru kararların alınması gerekmektedir. Bu kararlar ile tedarik zincirinde tahmin yapılabilmesi için taleplere, envanter seviyelerine ve risklere bakılması sağlanarak daha verimli gelecek planlamasının yapılmasına yol açmaktadır. Bu durumda işletmeler stratejik kararlar alarak rekabet ortamında daha başarılı olmaktadır.

Veri madenciliği ile tedarik zincirinde büyük miktarlardaki verilerin kullanılması ile müşterilerin davranışları, talepleri ve işletmenin süreçlerine dair birçok bilginin elde edilmesine olanak sağlamaktadır. Bu bilgiler ile işletmelerin çevik olması ile daha fazla müşterinin ve karın artmasına büyük bir katkı sağlamaktadır.

Bu çalışmanın amacı; veri madenciliği ile işletmelerin tedarik zincirini etkin kullanarak daha hızlı kararlar alınmasında ve rekabet ortamında sürekliliğini devam ettirebilmesini sağlamaktadır. Çünkü tedarik zincirinde bulunan sistemlerdeki verilerden daha faydalı raporların ve modellerin ortaya çıkarılması sağlanmaktadır. Bu veriler; ürünler, fiyatlar, satış miktarları ve bordrolar gibi matematiksel veriler olmaktadır. İşletmeler bu verileri depolayarak pazardaki paylarını öğrenerek ne kadar üretim veya hizmet edeceğini belirlemektedir.

Çalışmanın birinci bölümü tedarik zincirinin kavramsal çerçevesine dair ortaya bilgiler koymakta, ikinci bölümde veri madenciliğinin tanımı ve tedarik zincirinde veri madenciliğine dair bilgiler, üçüncü bölümde WEKA programı incelemesi yer almakta ve dördüncü bölümde ise araştırma için oluşturulan istatistiki analizler ve neticesinde elde edilen bulgular verilmektedir.


BİRİNCİ BÖLÜM

TEDARİK ZİNCİRİ KAVRAMI NEDİR?

Tedarik zincirini Martin & Towill (2000) yukarı ve aşağı yönlü olarak bağlantılar aracılığıyla ürün ve hizmetler şeklinde nihai müşterilere istek ve ihtiyaçlarına uygun olan değeri sağlayan farklı süreç ve faaliyetlerde bulunan işletmelerden oluşan bir ağ olarak tanımlamaktadırlar. Tedarik zinciri bu sayede birçok ağ yapısının oluşması ile müşterilere ürünleri ve hizmetleri daha hızlı ve etkin bir şekilde ulaşmasını sağlamaktadır. Tedarik zinciri bu ağ yapısı ile hammaddeleri elde etmek, depolamak, stoklamak, işlemek ve müşteriye sunulmasına kadar geçen bütün süreçleri birlikte uyum içerisinde hareket etmesini sağlayan bütünleşik bir sistemdir.

Tedarik zinciri, işletme dışındaki hammadde ve malzeme tedarikçileri, işletme içindeki yarı mamul ve malzeme tedarikçileri, bitmiş ürünleri ürüne dönüştüren üretim birimleri ve bitmiş ürünleri müşterilere ulaştıran toptancı ve perakendeciler gibi değer yaratan unsurları içerir ve nihai tüketiciye dağıtım kanalları aracılığıyla ulaştırmaktadır. (Güleş vd., 2009, s. 6).

Şekil-1: Tedarik Zincirinin Yapısı



Kaynak: Markland vd., 1998: 94


Ballou'nun (2004) tanımında ise "ürün ve hizmetlerin hammadde kaynaklarından son tüketicilere kadar dönüşümü ve hareketiyle ilgili operasyonları ve bunlara eşlik eden bilgi akışlarını kapsar". Tedarik zincirinde müşteri ve tedarikçi arasındaki bilgi ve malzeme alışverişinin sağlanması ile iş birliği oluşturulmaktadır. Bu sayede zincir sürdürülebilir olmaktadır.

süreçleri entegrasyonunun sağlanması, müşteri memnuniyetinin artırılması ve iş modellerinin oluşturulması gerekmektedir.

Zsidisin ve Ritchie'ye (2009) göre tedarik zinciri, hammaddenin temin edilmesine, ürünün üretimine, depolanmasına, taşınmasına ve son kullanıcıya ulaşarak, müşteri tarafından tüketilmesine kadar uzanan çeşitli aşamalar olarak tanımlanmaktadır. Stevens'a (1989: 3) göre tedarik zinciri, hammaddeler, yedek parçalar ve bitmiş ürünler, üreticiden müşteriye kadar olan süreçler içerisinde planlanmasını, koordinasyonunu ve kontrolünün sağlanması olarak tanımlamıştır.

Bilgi, malzeme ve paranın tedarik zinciri boyunca akması gerekir. Bu nedenle, etkileşimli tedarik zincirleri aracılığıyla fiziksel ürünlerin ve fonların normal akışını sağlayan, böylece işbirliğini ve entegrasyonu artıran bilgi akışlarının karşılıklı olarak gerçekleştirilmesidir. (Demirdöğen ve Küçük, 2007; Şen, 2006). Tedarik zincirindeki süreçlerin birbiriyle uyumlu ve birleşik bir şekilde etkileşimi, işletmelerin müşteri taleplerine ve ihtiyaçlarına daha süratli bir şekilde yanıt vermesini sağlamaktadır. Tedarik zincirinde koordinasyon, lojistik süreçlerini ileriye olan ve geriye olan bilgi akışını sağlarken aynı zamanda ileriye doğru malzeme akışını da sağlar; entegrasyon ise malzemelerin ve bilgilerin akışını planlayarak organize edilmesini sağlamaktadır. (Romano, 2003: 121). Etkili tedarik zinciri, işletmelerin stratejik hedeflerine ulaşmaları, maliyetleri düşürmeleri ve müşteri memnuniyetini artırmaları için kritik öneme sahiptir.

Şekil-3: Etkileşimli Tedarik Zinciri

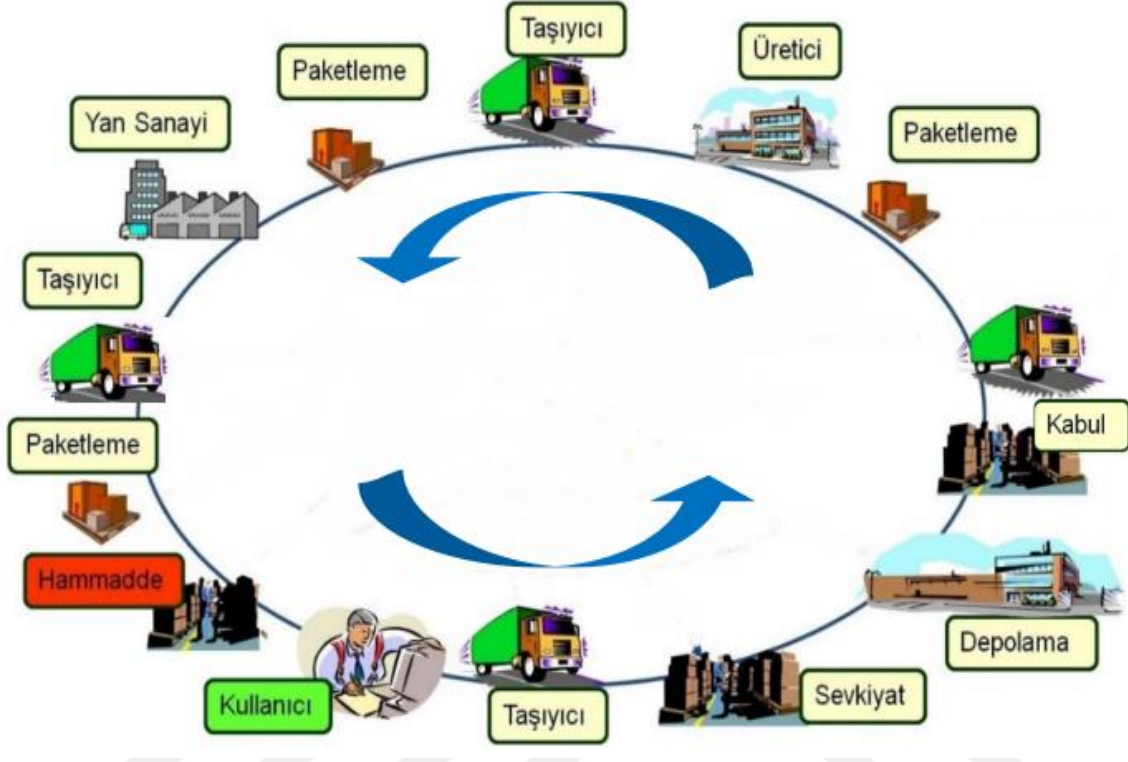


Kaynak: Yıldızöz, 2006: 10.

Tedarik zincirinde mümkün olan doğru ürünün, doğru zamanda, doğru yerde ve doğru fiyata alınması veya satılması için mümkün olan en düşük maliyetli malzeme, bilgi ve para akışını bütünleştiren yönetim ve müşterilerin olduğu bir sistemdir (Hubar, 2006). Bu sistem işletmelerin maliyetlerini düşürüp ve süreçlerini geliştirmesine yardımcı olmak amacıyla tedarikçilerine ve dağıtıcılarına yeni bağlantılar oluşturabilmesine (Timur vd., 2013), tedarik

zinciri kavramının akademik ve ticari dünyada 1990'lardan itibaren önemini artırmıştır (Svensso, 2002: 734).

Şekil-4: Tedarik Zinciri



Kaynak: Sevinç, 2008: 10.

Tedarik zinciri, müşteri ihtiyaçlarını karşılamak, kaynakları etkin ve verimli kullanmak, planlı, hızlı ve esnek tedarik, üretim ve dağıtım esasına göre oluşturulan Kavramsal zinciri oluşturmak için müşteriler, perakendeciler, üreticiler, tedarikçiler ve ortaklar arasındaki iletişimi ve işbirliği çalışmayı geliştirmektir. (Lysons, 2000).

Tedarik zinciri ekosistemindeki her bir paydaşın amacı, arz ve talep arasında kusursuz bir denge kurmak ve tedarik zincirindeki üretim sürecinden tüketim noktasına kadar olan aşamalardaki en güncel bilgileri bir sonraki işletmeye ileterek sürece katkıda bulunmakta ve en hızlı ve en düşük maliyetle ulaşım sağlamakta yer almaktadır (Güleş vd., 2009).

Tedarik zincirindeki süreçlerin gerçekleşmesi için gereken etkenler ise; üretimin yönetilebilmesi, ekonomik uygulamalar, dış kaynaklara dayandırılabilmesi, üretimin yönetilmesi, lojistik ve dağıtımın yönetilebilmesi, tedarik zincirinde bütünleşme teknikleri ve bilgi teknolojilerinin uygulanması gerekmektedir (Türköz, 2007). Bilgi teknolojilerinin uygulanması tedarik zincirinin rekabet ortamında daha hızlı ve çevik olmasını sağlamaktadır.

Bu durumda rekabet kavramı küreselleşme ve teknoloji alanında değişimlerin olmasıyla beraber farklı bir anlayış durumundayken işletmeler arasında sürekli var olan rekabeti ise işletmelerin bağlı oldukları tedarik zincirlerine taşımıştır (Paulraj ve Chen, 2007: 2-14).

Lummus ve Vokurka tedarik zinciri yapısının içerisinde bulunan süreç unsurları; kaynak teminin yapılması, planlamanın oluşturulması, üretimin yapılması ve teslimat şeklinde olduğunu Quinn (1997) ise tedarik zinciri unsurlarının yanında bilgi sistemlerinin süreç uygulamaları içerisinde kullanılması ve tedarik zinciri içinde bu süreçleri tedarik süreç elemanlarıyla kullanılmasını vurgulamaktadır. Tedarik zincirinde bilgi ve para akışının olması ürün yaşam döngüsünü etkileyen bir süreçtir. Bu yaşam döngüsü sürecinde ürünün veya hizmetlerin müşterilere teslim edilmesinden kullanılmasının bitmesiyle kadar geçen süreyi kapsamaktadır

Tedarik zinciri yapılarında Lummus ve Vokurka (1999) süreç elemanları; kaynakların elde edilmesi, planlamaların oluşturmak ve üretim aşamasının tamamlanması ve teslimat şeklinde olduğunda Quinn (1997), süreç uygulamalarında bilgi sistemlerinin ve tedarik zinciri elemanlarının kullanımını ve bu süreçlerin tedarik zinciri içerisinde tedarik süreci elemanları ile kullanılmasını vurgulamaktadır. Tedarik zincirinde bilgi ve fon akışı, ürünün yaşam döngüsünü etkileyen bir süreçtir. Bu yaşam döngüsü süreci, bir ürün veya hizmetin müşteriye teslim edilmesinden kullanımının tamamlanmasına kadar geçen süreyi kapsamaktadır (Kağnıcıoğlu, 2007, s. 9).

Tedarik zincirinin temel amaçlarının ifade edilmesinde müşteri memnuniyetini artırmak, ürünlerin üretim sürelerini azaltmak, envanter ve envanterle ilgili olan maliyetleri en aza indirmek, ürün hatalarının azaltılmasını sağlamak ve işlem maliyetlerini düşürebilmek ilk faaliyetler olarak kabul edilmektedir (Kehoe ve Boughton, 2001).

Tedarik zincirinde taşıma veya lojistiğin önemli olması nedeniyle, tedarikçiler, üreticiler, toptancılar, nakliyeciler, perakendeciler, distribütörler ve müşterilerin ihtiyaçlarını karşılayabilecekleri bir ağ içerisinde toplanmaktadırlar. Bu ağ içinde sağlam bir iletişim standardına ihtiyaç vardır, çünkü koordinasyonu güçlü tutarak tedarik zincirinde entegrasyonun faydalı olmasını sağlamaktadır. Böylece üretim aşamasından, envanterden ve dağıtım gibi birçok konu hakkında ortaklarıyla birlikte karar almaktadır.

Tedarik zincirinde kısa vadeli amaç gereksiz depolamaları ortadan kaldırmak, üretim yapmak ve müşteriye cevap vermek için daha hızlı olması gerekirken uzun vadeli amacıysa

müşterinin isteklerini karşılayan ürünleri doğru yerde teslim etmiş olması ve müşterinin ürünle karşılaşması sonucunda pazar payının ve karının arttırılmasını sağlamaktadır (Güleş vd., 2009, s. 8).

Tedarik zinciri teknik olarak hammadde ve malzemelerin temin edilmesi süreçlerini yürüterek, bunları yarı mamul ve mamul ürünlere dönüştürdükten sonra bu ürünlerin dağıtım kanallarıyla birlikte müşterilere ulaştırılmasını sağlayan araçlardır. Bu ağ sayesinde malzemeler tedarik edilerek, malzemeleri bileşenlerine veya son ürün haline dönüştürülmesini sağlayarak kullanıcı olan müşteriye ulaştırılmasıyla dağıtım işlevini yerine getirmektedir (Özkan vd, 2015).

Tedarik zinciri pazarda bulunan her bir ürün için envanter ve nakliye süreçlerinde daha hızlı ve etkin olmasını sağlayarak verimli sistem oluşturmaktadır. Müşterilerin istek ve ihtiyaçlarına uygun ürün veya hizmet üreten her bir işletme bir tedarik zinciri içerisinde yer almaktadır. Böylelikle tedarik zincirinde uzun vadeli ve kısa vadeli uygulamalar bulunmaktadır. Tedarik zincirinin kısa vadeli hedefleri, gereksiz depolamayı ortadan kaldırmak, daha hızlı üretim yapmak ve müşterilere yanıt vermek iken, uzun vadeli hedefler, ürünleri müşteri ihtiyaçlarını karşılayan doğru yerlere teslim etmek ve pazar payını ve karını arttırmak ve müşterilerin o ürünle karşılaşmasının bir sonucudur (Güleş vd., 2009: 8).

Tedarik ve talep yönetimini, hammaddenin tedarik edilmesini, üretim ve montajın, envanter yönetiminin, sipariş yönetimini ve müşterilere ürünlerin dağıtılmasının yanı sıra tüm bu süreçlerin desteklemesini sağlayan bilgi sistemlerini kapsamaktadır (Akman ve Alkan, 2006). Bu sistemlerde bilinçli kararlar almak için işletmenin ihtiyaç duyduğu bilgilere sahip olmasını sağlamak amacıyla tedarik zincirinin farklı aşamaları arasındaki bilgi akışının yönetilmesini içerir. Bu bilgi paylaşımının temel amacı ise aşamalarda yaşanacak olan sorunlara çözüm üretilebilmesi ve değişken müşteri beklentisi, pazar koşulları ve rekabet hareketlerindeki hızlı tepkilerin verilebilmesi için tedarik zincirinden farda sağlamaktadır (Kara ve Yücekaya, 2021: 105).

Tedarik zinciri, tedarikçiler ve alıcılar arasında bulunan süreçlerde maliyetlerin çok daha düşük fiyatlara ve çok daha yüksek katma değerli olacak şekilde yönetilmesini sağlamaktadır (Christopher, 2005). Bu sayede işletmeler karlarını en üst seviyeye çıkartarak rekabet etmede ve pazarda daha iyi bir konuma gelmektedir. Tedarik zinciri her işletmenin önemli bir bileşenidir ve verimliliği ve etkinliği bir şirketin kârlılığını büyük ölçüde etkileyebilir.

Lambert vd. (1998) tedarik zinciri pazarda bulunan ürünlerin ve hizmetlerin sağlanması için işletmelerle uyumu içerisinde çalışması olarak tanımlamaktadır. Chopra ve Meindl (2001) tedarik zincirini ise alıcıların isteklerini ve taleplerini karşılayan ve sadece üretici ve tedarikçilerin değil, aynı zamanda da nakliyeciler, depo hizmeti sağlayıcıları, perakendecileri, alıcıları ve diğer bileşenleri de zincir içerisinde tanımlamaktadır. Ayers'a (2000) göre tedarik zinciri, tedarikçilerin ürettiği ürün ve bilgileri alıcıların istek, ihtiyaç ve taleplerine göre müşterilere gönderilmesine ilişkin devam etmekte olan süreç yönetimi olarak tanımlamaktadır.

Hill (1998) tedarik zincirinin müşterilere ihtiyaç duyduğu ürünlerin ve bu ürünler için servis hizmetlerini karşılaması ve gerekli olan aşamalar ve bu aşamalardaki görev alan tüm unsurların oluşturmuş olduğu bir bütün şeklinde açıklamaktadır.

Tedarik zincirinde üretilen ürünler için (Houlihan, 1985) depolar ve mağazaların aktif bir şekilde entegre edilmesini sağlayarak işletmenin stratejik açıdan taktiksel ve operasyonel düzeye kadar çeşitli durumları içerisinde barındırmaktadır.

İşletmeler ve tedarik zincirinin performansını artırmak için belirli bir işletme ve tedarik zincirinde bulunan işletmeler içinde işletme fonksiyonlarını ve bu fonksiyonlardaki koordinasyonu sağlamaktadır.

Tedarik zincirinde bulunmakta olan ana bileşenler şunlardır:

1. Aktörler: Tedarik zinciri içerisindeki kişi ve kurumlar bütünüdür. Tedarikçiler, müşteriler, üreticiler, nakliyeciler, hizmet sağlayıcılar, depolar ve dağıtım kanalı üyeleri
2. Kaynaklar: İnsan kaynağı, soyut ve somut kaynaklar bütünüdür. Malzemeler, finansal kaynaklar ve bilgi.
3. Faaliyetler: Ürünlerin dönüşüm işlemleri, ticari işlemler ve işletme döngülerini içermektedir. Tedarik, teslimat, hizmet ve planlama.

Tedarik zincirinin paydaşları:

1. Üreticiler: İmalatçılar hammadde, yarı mamul veya mamul şeklinde ürünler üretmektedir.
2. Tedarikçiler: Tedarik zincirinde üretim aşamalarına gerekli olan girdileri sağlamaktadır.

3. Müşteriler: Tedarik zincirinde ortaya çıkan ürünlerden müşterinin istek ve ihtiyacına uygun olan ürünü almaktadır.
4. Dağıtıcılar: Tedarik zincirinde yer alan işletmeler üretilen ürünlerini dağıtım yapmaktadır.
5. Perakendeciler: Ürünü nihai tüketici olan müşteriye ulaştıran araçlardır.
6. Taşıyıcılar: Zincirde bulunan tüm paydaşlar arasındaki taşıma işlemini gerçekleştirmektedir.
7. Depolar: Tedarik zincirindeki ürün akışının sürekliliğinin devam etmesi için işletmenin kendi içerisinde kurduğu hizmet ya da bu hizmeti alabilecekleri işletmelerden faydalanabilmelerini sağlamaktadır.
8. Hizmet Sağlayıcılar: Tedarik zincirinin tamamında hizmetler sunmakta olan üçüncü taraf kuruluşlardır.

Bu paydaşların her birinin tedarik zincirinde oynayacağı benzersiz bir rol vardır ve eylemleri genel süreç üzerinde önemli bir etkiye sahip olabilmektedir.

Tedarik zincirinin aşamaları şunlardır:

1. Talep Etme: müşterilerden alınmış olan siparişleri en kısa zamanda ve en uygun bir şekilde teslim edilmesi için planlama yapmaktadır.
2. Satın Alma: Üretim için gerekli olan hammadde ve malzemelerin kaliteli, az maliyetli, hızlı ve güvenli bir şekilde alınmasını sağlamaktadır.
3. Planlama: Üretimde gerekli olan süreçlerdeki maliyetlerinin tahminlemesini doğru bir şekilde planlamaktadır.
4. Üretim: tedarik edilen hammadde ve malzemelerin müşterinin gereksinimlerine uygun bir şekilde ve zamanda üretilmesini sağlamaktadır.
5. Envanter: Üretim sürecindeki planlamalara göre ihtiyaç olan malzemeleri en uygun maliyet ile gerekli miktarda tedarik edilmesini sağlamaktadır.
6. Depo: Stoklanan ürünlerin hangi koşullarda saklanacağını planlayarak yönetmektedir.
7. Nakliye: Nihai ürünleri son tüketici olan müşteriye depodan nakledilmesi süreci yönetmektedir.

Tedarik zinciri yapı bakımından kendisini taşımacılık faaliyetinden ayırarak bu faaliyeti de kendi içerisinde barındırarak tedarik noktasından başlayan nihai tüketici olan müşteriye

ulaşmasına kadar olan tedarik faaliyetinin gerçekleşmesi için tüm süreçleri, elemanları ve aktiviteleri bulundurmaktadır (Eymen, 2007: 5). Tedarik zinciri süreci planlama, kaynak bulma, üretim, teslimat ve iade gibi çeşitli aşamalardan oluşur. Planlama, talebin tahmin edilmesini, üretim programlarının belirlenmesini ve envanter seviyelerine karar verilmesini içerir.

Tedarik zincirinde aşamaların müşterinin istek ve ihtiyaçlarına uygun olan ürünlerin daha hızlı, daha az fiyatla ve daha kaliteli gönderilmesi için, zincirde bulunan iş süreçlerinin entegre olmasını sağlamak, müşteri memnuniyetinin artmasına ve iş modellerinin oluşturulması gerekmektedir.

Su ve Yang (2010) tedarik zincirini “geliştirme, satıcılardan malzeme tedariki, malzemelerin tesisler arasında hareketi, ürünlerin imalatı, bitmiş ürünlerin müşterilere dağıtımı ve sürdürülebilirlik için pazar sonrası destek işlevlerini yerine getiren tesisler ve faaliyetler ağı” olarak tanımlamaktadır.

Tedarik zincirinde ürün yolculuğunun her aşamasında teknoloji ve internet sistemlerinin dahil edilmesiyle birlikte, uzakta olan tedarikçi ve müşteri arasındaki etkileşimi kolaylaştırmak için kullanılmaktadır. Tedarik zincirinin her bir aşamasında sürekli olarak insan ve teknolojinin entegre halde olması dinamik bir tedarik zincirini ortaya çıkarmaktadır. Bir tedarik zincirini yönetmenin en önemli zorluklarından biri, tüm paydaşların birlikte etkin bir şekilde çalışmasını sağlamaktır. Bu, ilgili tüm taraflar arasında açık iletişim, koordinasyon ve iş birliği gerektirir. Buna ek olarak, süreci etkileyebilecek olası gecikmeleri veya diğer sorunları belirlemek için tüm tedarik zincirinde görünürlüğe sahip olmak çok önemlidir.

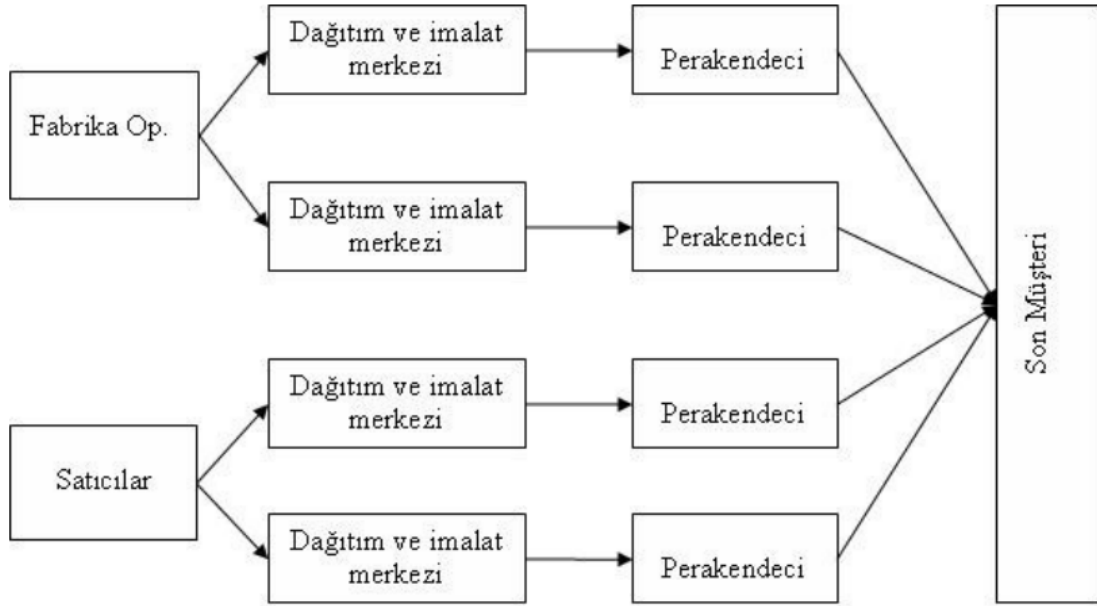
Tedarik zinciri, tedarik zincirinde bulunan paydaşların taleplerini ve tedarik akışlarını uyumlu bir hale getirilmesi için kullanılmakta olan iletişim ve taşıma sistemlerinin birbiriyle en güvenli şekilde iç içe geçmiş bir ağ olmasını sağlamaktadır (Russell ve Taylor, 2009). Fugate vd. (2006: 132) göre tedarik zinciri finansal, malzeme ve bilgi akışlarının birbirleriyle bağlantılı olan ticari ortaklar arasında oluşan etkileşimli bir yapı olarak tanımlamaktadır. Tedarik zincirindeki bütün halkaların birbirleriyle oluşturmuş oldukları etkili ağ sayesinde her bir paydaş için müşteriye olan değeri ve karı en üst seviyeye çıkartmaktadır. Bu durumda tedarik zinciri faaliyetlerini daha etkin ve verimli bir şekilde artmasını sağlamaktadır.

Tedarik zincirinin karşılaştığı en önemli zorluklardan biri tedarik zincirinin esnekliğini sağlamaktır. Bu, doğal afetler veya tedarik zinciri kesintileri gibi aksaklıklara hızlı bir şekilde yanıt verme becerisini içerir. Bu, tedarikçileri çeşitlendirmek, acil durum planları geliştirmek

ve tedarik zinciri görünürlüğünü ve izlenebilirliğini iyileştirmek için teknolojiye yatırım yapmak gibi risk yönetimi stratejileriyle başarılabilir.

Ürünlerin maliyetini, kalitesini ve müşterilere sunula bilirliliğini doğrudan etkilediği için etkili bir tedarik zincirinin önemi artmaktadır. Tedarik zincirinin etkili olması her işletmenin başarısı için kritik öneme sahiptir ve tedarikten nakliye ve lojistiğe kadar birbiriyle bağlantılı çok sayıda süreci içerir.

Şekil-5: Tedarik zincirinde ürün akışı



Kaynak: Poirier, 1999.

Tedarik zinciri, işletmelerin kaynaklarını etkin bir şekilde yönetmelerini, maliyetleri azaltmalarını ve müşteri memnuniyetini artırmalarını sağlayan, iş başarısının kritik bir bileşenidir. Bunu başarmak için işletmelerin paydaşlar arasında etkili iletişim ve iş birliği kurmaları, teknolojiye yatırım yapmaları ve tedarik zincirinin esnekliğini ve sürdürülebilirliğini sağlamaları gerekir.

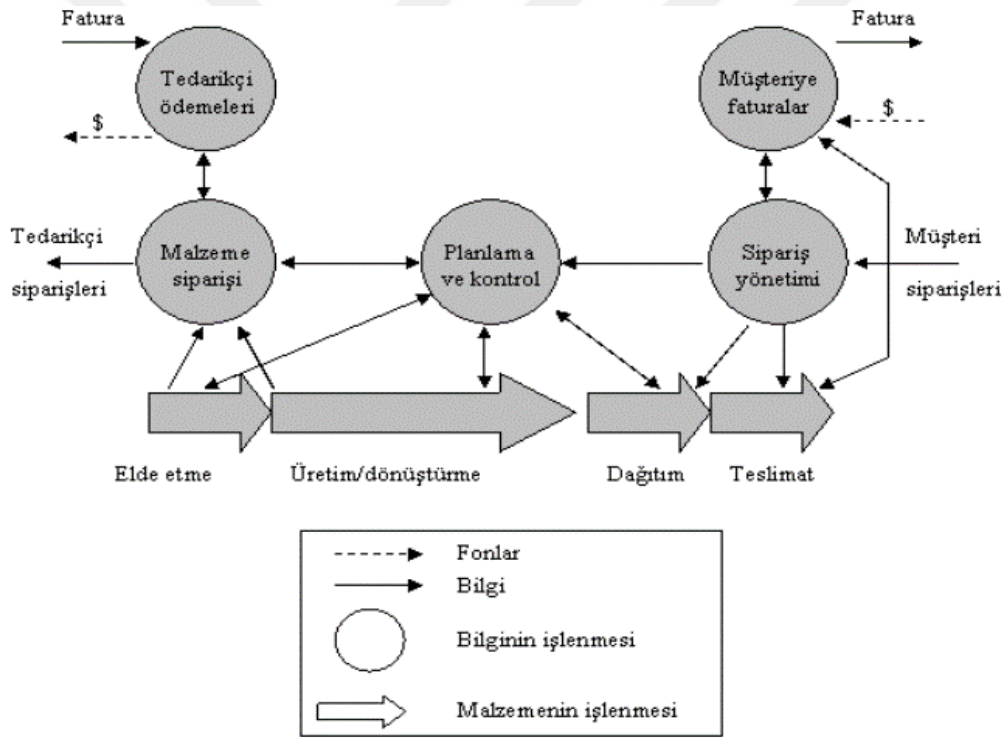
Küresel tedarik zincirlerinin artan karmaşıklığıyla birlikte, işletmelerin rekabetçi kalabilmek ve müşteri beklentilerini karşılayabilmek için teknolojiden yararlanmaları ve en iyi uygulamaları benimsemeleri gerekmektedir.

Tedarik zinciri artan karmaşıklığa göre tek safhalı ve çok safhalı tedarik zincirleri olarak çeşitlilik göstermektedir. Tek aşamalı tedarik zinciri yapısı, tedarikten üretime ve dağıtımına

kadar tüm tedarik zinciri sürecinden sorumlu tek bir kuruluşu veya tüzel kişiyi içeren basitleştirilmiş bir tedarik zinciri modelidir. Bu yapıda kuruluş, hammadde tedarikinden bitmiş ürünlerin müşterilere teslimine kadar tedarik zinciri sürecinin tüm yönlerini yönetmekten sorumludur. Tek aşamalı tedarik zinciri yapısı genellikle sınırlı kaynaklara sahip olan ve tedarik zinciri operasyonlarını basit tutmaya ihtiyaç duyan küçük işletmeler veya yeni başlayanlar tarafından kullanılır.

Tek safhalı tedarik zincirinde birçok bilginin ve malzeme akışının temel alınması yapı içerisindeki ortakların tek safhalı tedarik zincirinde bulunmaktadır (Uran, 2004: 8). Bu akışın faaliyeti, zaman ve maliyet minimizasyonu, teknolojinin kullanılmasındaki maksimizasyonu ile bağlantılı olarak görülmektedir (Gedikli, 2006).

Şekil-6: Tek safhalı tedarik zinciri



Kaynak: Metz, 1998, s. 22.


Tek aşamalı tedarik zinciri yapısının da bazı sınırlamaları olmaktadır. Ayrıca bu yapı, kuruluşun uzman tedarikçilerden veya dış kaynak kullanımı seçeneklerinden yararlanma kabiliyetini sınırlayabilmektedir.

Çok safhalı tedarik zincirinde birden fazla tek safhalı tedarik yapısı bulunmaktadır (Metz, 1998). Çok safhalı tedarik zinciri yapısı, tedarik zinciri sürecinin farklı aşamalarından sorumlu birden fazla kuruluşu veya tüzel kişiliği içeren daha karmaşık bir tedarik zinciri modelidir. Bu

yapıda her kuruluş tedarik zinciri sürecinin tedarik, üretim veya dağıtım gibi belirli bir yönünden sorumludur.

İşletmeler, tedarik zinciri yönetiminde en iyi uygulamaları benimseyerek ve doğru teknoloji çözümlerine yatırım yaparak çok aşamalı tedarik zinciri operasyonlarını optimize edebilir ve daha fazla verimlilik, daha düşük maliyet ve daha iyi müşteri memnuniyeti elde edebilir.

Şekil-7: Çok Safhalı Tedarik Zinciri



Kaynak: Metz, 1998, s. 23.

Tedarik zinciri her işletmenin kritik bir bileşenidir ve verimliliği ve etkinliği bir şirketin başarısı üzerinde önemli bir etkiye sahip olabilir. İşletmeler envanter seviyelerini yöneterek, süreçleri optimize ederek ve görünürlük ve içgörü elde etmek için teknolojiden yararlanarak tedarik zinciri operasyonlarını iyileştirebilir ve günümüz pazarında rekabet avantajı elde edebilir.

Tedarik zincirinde işlemlerin hızlı, etkin ve verimli bir şekilde yapılması için günümüzde kullanılmakta olan teknolojilerden de yararlanmaktadır. Tedarik zinciri teknolojiyi kullanarak paydaşlarıyla ve müşterilerle olan ilişkisini en iyi şekilde yöneterek işletmelerin kar ve rekabet ortamında daha verimli olmasını sağlamaktadır. Bu sayede işletmeler tedarik zincirinde oluşabilecek aksaklıklardan dolayı planlamalarını teknolojiyle birlikte hazırlayarak hem rekabette hem de kar elde etme konusunda üstünlük sağlayarak pazar paylarını arttırmaktadırlar.

Tedarik zinciri işlevlerinin etkin yönetimi, sürekli iyileştirmeye, teknoloji kullanımına ve kuruluşlar arasında etkin iş birliğine odaklanmayı gerektirir. İşletmeler, tedarik zinciri işlevlerini optimize ederek maliyetleri düşürebilir, verimliliği artırabilir ve müşteri deneyimini geliştirebilir.

Tedarik zincirinde kullanılmakta olan teknolojiler sayesinde son yıllarda tedarik zincirinin dönüştürülmesinde önemli bir rol oynamıştır. Veri analitiği, yapay zeka ve Nesnelerin İnterneti (IoT) alanındaki gelişmeler, tedarik zinciri hakkında gerçek zamanlı olarak büyük miktarda veri toplanmasını ve analiz edilmesini mümkün kılmaktadır. Bu veriler trendleri belirlemek, talebi tahmin etmek ve süreçleri optimize etmek için kullanılabilir, böylece verimlilik artar ve maliyetler düşer.

Nesnelerin İnterneti (IoT), yapay zeka (AI) ve blok zinciri gibi teknolojideki gelişmeler de tedarik zinciri yönetimini dönüştürmektedir. IoT sensörleri ürünleri takip etmek ve tedarik zinciri performansını gerçek zamanlı olarak izlemek için kullanılabilirken, yapay zeka verileri analiz etmek ve gelecekteki talep hakkında tahminlerde bulunmak için kullanılabilir. Blok zinciri teknolojisi şeffaf ve güvenli tedarik zinciri ağları oluşturmak, dolandırıcılık riskini azaltmak ve izlenebilirliği iyileştirmek için kullanılabilir.

Tedarik zincirinde kullanılmakta olan bilişim teknolojileri şunlardır;

1. RFID (Radyo Frekansı ile Tanımlama): RFID teknolojisi, tedarik zinciri boyunca malların gerçek zamanlı takibini ve görünürlüğünü sağlar. Verimli envanter yönetimini kolaylaştırır, stok tükenmelerini azaltır, sipariş karşılama doğruluğunu artırır ve genel tedarik zinciri verimliliğini geliştirir.
2. Elektronik Veri Değişimi (EDI): İşletmeler arasında iş belgelerinin ve bilgilerin standartlaştırılmış bir elektronik formatta değiş tokuş edilmesini sağlayan teknoloji odaklı bir süreçtir. İş operasyonlarını kolaylaştırmada, verimliliği artırmada ve ticaret ortakları arasındaki iletişimi geliştirmede çok önemli bir rol oynar.
3. Barkod: Barkod teknolojisi sayesinde ürünlerin takip edilebilmesine, etiketlenmesine ve otomatik olarak tanımlanmasına yardımcı olmaktadır. Böylelikle ürünlerin izlenebilirliği ve kayıt işlemlerinin takip edilmesinde önemli bir rol oynamaktadır.

4. Coğrafi Bilgi Sistemleri (GPS): İşletmenin kurduğu çağrı merkezi yardımıyla GPS sistemi, aracın konumunu tespit ederek, rotayı gerçek zamanlı olarak optimize edip günceller ve harita üzerinde değiştirilen sürüş rotasını mobil terminale göndermektedir (Pagani, 2005). Bu, optimum araç yolu planlaması sağlamaktadır.
5. Blok Zincir: Tedarik zinciri boyunca toplanan veriler katılımcılara gösterilerek şeffaflık sağlanıyor ve bir ürünün dijital ayak izi, üretiminden dağıtımına ve hatta satış sürecine kadar takip edilebilmektedir (Patel, Bothra, & Patel, 2017).
6. Gelişmiş Planlama ve Çizelgeleme (APS): Birçok ERP ve APS sistemi, tedarikçileri ve müşterileri planlama prosedürüne dahil etmeyi ve böylece tüm tedarik zincirini gerçek zamanlı olarak optimize etmeyi mümkün kılar (Berchet & Habchi, (2005).
7. Kurumsal Kaynak Planlaması (Enterprise Resource Planning – ERP): İşletmenin stratejik amaç ve hedeflerinde belirtilen müşteri ihtiyaç ve taleplerinin uygun bir şekilde karşılanabilmesi için farklı coğrafi konumlarda bulunan tedarik, üretim ve dağıtım kaynaklarını işletme için aktif ve verimli kullanılması, planlanmasının yapılması, koordine edilmesi ve kontrol edilebilmesi fonksiyonlarını içerisinde bulunduran bir yazılım sistemdir (Keçek & Yıldırım, 2009).
8. Otomatik kalite kontrol sistemi (AQCS): Otomatik Kalite Kontrol Sistemi (AQCS), çeşitli endüstrilerdeki ürünlerin veya süreçlerin kalitesini incelemek, analiz etmek ve sağlamak için gelişmiş sensörler, makine görüşü, yapay zeka (AI) ve otomasyon kullanan teknolojik bir çözümdür. AQCS, manuel yöntemlere kıyasla daha hızlı, daha doğru ve daha verimli denetimler sağlayarak kalite kontrol uygulamalarında devrim yaratmıştır.
9. Depo Yönetim Sistemleri (WMS): Depo Yönetim Sistemleri (WMS), depo operasyonlarının verimli bir şekilde yönetilmesini ve kontrol edilmesini kolaylaştıran yazılım çözümleridir. Teslim alma, teslim etme, envanter takibi, sipariş toplama, paketleme, sevkiyat ve döngü sayımı dahil olmak üzere çeşitli depo faaliyetlerini yönetmek ve kontrol etmek için merkezi bir platform görevi görmektedir.
10. Nakliye Yönetim Sistemleri (TMS): Nakliye Yönetim Sistemleri (TMS), kuruluşların nakliye operasyonlarını verimli bir şekilde yönetmelerine ve optimize etmelerine yardımcı olan yazılım çözümleridir. TMS, taşıyıcı seçimi, rota optimizasyonu, sevkiyat takibi ve navlun ödemesi dahil olmak üzere nakliye

faaliyetlerinin planlanması, yürütülmesi ve izlenmesi için merkezi bir platform sağlamaktadır.

11. Kargo ve Araç Yükleme Optimizasyonu (CLO): Kargo ve araç yükleme optimizasyonu, kargo alanının verimli bir şekilde kullanılması ve araç yüklemesinin optimize edilmesi maliyet tasarrufu, gelişmiş güvenlik ve gelişmiş operasyonel verimlilik sağlayabilir. Kargo ve araç yükleme optimizasyonu, yük kapasitesini en üst düzeye çıkarmak, dengeyi sağlamak ve nakliye kaynaklarını optimize etmek için yükün araçlar içinde verimli bir şekilde organize edilmesi ve dağıtılması sürecidir. Boşa harcanan alanı en aza indirmek ve dengeli yük dağılımı sağlamak için malların boyutları, ağırlıkları ve uyumlulukları dikkate alınarak en uygun şekilde düzenlenmesini içermektedir.
12. Malzeme İhtiyaç Planlaması (MRP - Materials Requirement Planning): MRP, işletmelerin malzeme tedarik ve üretim süreçlerini optimize etmelerine yardımcı olarak verimliliğin artmasını, maliyetlerin düşmesini ve müşteri memnuniyetinin üst seviyeye çıkmasını sağlamaktadır. Böylece üreticilerin üretim malzemelerini etkin bir şekilde yönetmelerine, envanterin zamanında hazır bulunmasını sağlamalarına ve müşteri taleplerini karşılamalarına yardımcı olan çok önemli bir süreçtir.
13. Müşteri İlişkileri Yönetimi (CRM - Customer Relationship Management): Müşteri ilişkilerinin amacı ise; işletme modellerini, süreç metodolojilerini ve interaktif teknolojilerin kullanılması ile müşteriler kazanması ve müşteri bağlılığını yukarı seviyelere çıkarmasıyla sürdürülebilmektedir (Canpolat, 2014).
14. İmalat Kaynak Planlaması (MRP II – Manufacturing Resource Planning): MRP II, işletmelerin üretim süreçlerini planlamalarına ve kontrol etmelerine, kaynak kullanımını optimize etmelerine ve üretimi müşteri talebiyle eş zamanlı olarak işlem yapılmasında yardımcı olmaktadır.
15. İş Zekası (BI – Business Intelligence): İş zekası uygulamaları, yöneticilerin anlık karar alma yeteneklerini desteklemek amacıyla veriler üzerinde araştırmalar yapar, raporlamalar gerçekleştirir, detaylı analizler geliştirir, veri madenciliği ve istatistiksel incelemelere dayalı tahminler oluşturur, görsel teknikler kullanır; veri raporlaması ve verilerin farklı sistemlere dağıtımında ve kontrol edilmesinde olanaklar sunan bir yapıdadır (Kabakchieva, 2015).
16. Tedarik Zinciri Yönetimi (SCM - Supply Chain Management): Tedarik zinciri yönetimi, hammadde işlemlerinin nihai ürüne dönüştüğü veya hizmetlerin gerekli

süreçlerden geçiş yaparak son kullanıcıya iletiildiği süreçte, bilgi akışının ve maliyetlerin göz önünde bulundurularak müşterilere ulaşmak amacıyla çeşitli düzeylerde işletmeler arasındaki iletişim ağı veya sistemler bütünlüğü olarak tanımlanmaktadır (Langley vd., 2008, s. 17). Etkili tedarik zinciri yönetimi uygulamalarının benimsenmesi, işletmelerin işbirliğini geliştirmesine, görünürlüğü artırmasına, riskleri azaltmasına ve operasyonel mükemmelliği artırmasına olanak tanıyarak sonuçta pazarda sürdürülebilir başarıya yol açmaktadır.

17. Dağıtım Kaynakları Planlaması (DRP – Distribution Resource Planning): DRP, siparişlerin sorunsuz bir şekilde yerine getirilmesini sağlamada, teslim sürelerini azaltmada, envanter seviyelerini optimize etmede ve dağıtım maliyetlerini en aza indirmede hayati bir rol oynamaktadır. İşletmeler, sağlam DRP sistemleri ve süreçleri uygulayarak dağıtım operasyonlarını düzenleyebilir, tedarik zinciri performansını artırabilir ve müşteri beklentilerini etkili bir şekilde karşılayabilmektedir.
18. Kapasite İhtiyaç Planlaması (CRP – Capacity Requirement Planning): Kapasite İhtiyaç Planlaması (CRP), üretim taleplerini karşılamak için gereken kapasiteyi belirlemeye ve yönetmeye odaklanan imalat ve üretim ortamlarında kritik bir süreçtir. Üretim gereksinimlerinin analiz edilmesini, mevcut kaynakların değerlendirilmesini ve optimum üretim seviyelerini sağlamak için bu kaynakların etkin bir şekilde tahsis edilmesini içermektedir.

1. 1. Tedarik Zincirinin Fonksiyonları

Tedarik zinciri fonksiyonlarının etkin yönetimi, sürekli iyileştirmeye, teknoloji kullanımına ve kuruluşlar arasında etkin iş birliğine odaklanmayı gerektirir. İşletmeler tedarik zincirini sürekli analiz ederek iyileştirme fırsatlarını belirleyebilir ve verimliliği ve kârlılığı artırmak için süreçlerini optimize edebilmektedir. Tedarik zincirinde oluşan birçok olayların hızlı ve kaliteli bir şekilde karşılık verebilmesini sağlayabilmek için firma çerçevesinde birçok fonksiyonu koordine edilmesi gerekmektedir (Özceylan, 2010, s. 4). Bu koordinasyonu sağlamak için tedarik zinciri ağı boyunca mal ve hizmetlerin sorunsuz akışını sağlamak ve birlikte çalışan çeşitli fonksiyonları içerisinde bulundurması gerekmektedir. Böylelikle tedarik zinciri ağında bulunan fonksiyonların işlevleri daha etkin bir şekilde çalışmasını sağlamaktadır. Aşağıda tedarik zincirinin temel fonksiyonlarından bazıları yer almaktadır:

- ❖ Tedarik
- ❖ Üretim
- ❖ Planlama
- ❖ Sipariş
- ❖ Stok Yönetimi
- ❖ Depolama
- ❖ Envanter
- ❖ Dağıtım
- ❖ Müşteri Hizmetleri

Tedarik zincirindeki fonksiyonlar sayesinde gereksiz aşamaların ortadan kaldırılması, süreçlerin iyileştirilmesi, yüksek katma değerli ürün ve hizmetlerin ortaya çıkarılması, pazarda ortaya çıkan anlık değişimlere hazırlıklı olunmasını, süreç boyunca gerçekleşen tüm teslimatların hasarsız bir şekilde sağlanması ve verimliliğin artırılması gibi faydalar sağlamaktadır.

1.1.1. Tedarik Fonksiyonu

Tedarik fonksiyonu mal veya hizmet üretimi için gerekli hammaddelerin ve diğer girdilerin tedarik edilmesini içermektedir. Etkili tedarik fonksiyonu için güvenilir tedarikçilerin belirlenmesini, uygun koşullarda pazarlık yapılmasını ve girdilerin zamanında teslim edilmesini gerektirir.

Tedarik fonksiyonu; makul fiyatla, yeterli standart ve miktar ile üretimin, zamanında iletim ile hammadde, ekipman ve malzemelerin temin edilmesi olarak tanımlanır. (Dağdeviren ve Eren, 2001, s. 42). Tedarik fonksiyonunun bu işlevleri yapması için gerekli kaynağı bulması, üretim, teslimat, iade gibi süreçlerin planlanmasını sağlayarak işletmelerin kar ve verimlilik oranlarını arttırmaktadır. Bu sayede üretilen ürünler son tüketici olan müşteriye ulaşmasını daha hızlı ve etkin bir şekilde yapılmasını sağlamaktadır.

Tedarik fonksiyonu ürünlerin istenilen kalitede ve miktarda üretilmesini sağlayarak en uygun fiyat ve zamanda müşterinin ihtiyacını karşılamaktadır. Bu sayede de işletmelerin etkinlik ve karlılığını sağlayarak önemli ölçüde etkileyici bir rol üstlenmektedir.

Tedarik fonksiyonu ürünlerin ve hizmetlerin ortaya çıkması için uygun olan tedarikçilerle iş birliği içerisinde bulunulmasını sağlamaktadır. Bu sayede de mevcut tedarikçilerle olan

iletişimi daha sağlıklı hale getirilmesinde rol oynamaktadır. Tedarik zincirinde bulunan tedarikçilerin herhangi bir aksaklık durumundan dolayı işlerin durmasına yol açabilecek ihtimallerinde göz önünde bulundurulmasını sağlamaktadır.

Tedarik fonksiyonu işletmenin ihtiyaç duyduğu ürün ve hizmetleri en uygun maliyetle ve güvenilir kaynaklardan elde edilmesini sağlamaktadır (Scheuing, 1984: 4). Bu sayede ürün ve hizmetlerin ihtiyaca göre belirlenmesini, tedarikçilerin seçilmesini, sözleşmelerin oluşturulmasını, siparişlerin verilmesini, mal ve hizmetlerin teslim alınması ve denetlenmesi ve tedarikçilere ödeme yapılması gibi çeşitli aşamaları içermektedir. Böylelikle tedarik fonksiyonu, bu aşamaları verimli ve uygun bir şekilde yönetilmesini ve aynı zamanda tedarikçilerin kalite ve teslimat gereksinimlerinin karşılanmasını sağlamaktadır.

Tedarik fonksiyonu etkili bir şekilde uygulanması ile maliyette azalma, gelişmiş tedarikçi ilişkileri, verimlilik ve azalan riskler dahil olmak üzere birçok fayda sağlamaktadır. Bu faydalar sayesinde güçlü ilişkilerin kurulmasına yardımcı olurken, kaliteli ürün ve hizmetlerin daha iyi bir şekilde kısa sürede teslim edilmesini sağlayabilmektedir.

Tedarik fonksiyonu ile işletmeler, tedarikçilerin performansını kayıt altına alarak takip etmekte ve bu sayede iyileştirmeye açık olan alanları belirleyerek tedarik zincirini optimize etmektedir (Wankhade ve Kundu, 2018). Tedarikçi performansını değerlendirme süreci ile kalite durumu sürekli kontrol altında tutularak kalite sorunlarının zamanında tespit edilmesi ve kalite göstergeleri kötüleşen tedarikçilere daha fazla odaklanılarak büyük sorunların ortaya çıkmadan önlenmesi sağlanır (Dey vd., 2015). Bu, tedarik sürelerinin kısaltılmasına, envanterin iyileştirilmesine ve tedarik zincirindeki aksaklıkların en aza indirilmesine yardımcı olur. Bu, zincirdeki tedarikçilerin doğru ürünleri, doğru yere, doğru zamanda ve doğru maliyetle teslim etmesini sağlar (Gultom ve Wibisono, 2019).

1.1.2. Üretim Fonksiyonu

Üretim, hammaddelerin imalat veya montaj süreçleri yoluyla bitmiş ürünlere dönüştürülmesini içerir. Etkili üretim, verimli süreçler, etkili kalite kontrolü ve operasyonları optimize etmek için teknolojinin kullanılmasını gerektirir.

Şirketin hedeflerine ulaşabilmesi için üretim planlamasının doğru bir şekilde etkin bir biçimde düzenlenmesi kritik öneme sahiptir (Demirdöğen ve Küçük, 2007). Böylelikle belirli

miktarda girdi verildiğinde bir ürün veya hizmetten ne kadar üretilebileceğini açıklanmasını sağlamaktadır.

Üretim fonksiyonu, üretimin verimliliğini analiz etmek ve belirli bir ürün düzeyini üretmek için kullanılması gereken en uygun girdi bileşenlerini birleştirerek belirlemek için kullanılabilir. Ekonomistler ve yöneticiler, her bir girdiden ortaya çıkacak olan ürün ve hizmetlerin verimliliğini analiz ederek, üretimin iyileştirilebileceği alanları belirleyebilir ve kaynakların en verimli kullanımını tespit edebilmektedir. Bu sayede mal ve hizmet üretiminin en uygun maliyetli yolunu tespit edebilmektedirler.

Üretim fonksiyonu, firmaların üretimle ilgili kararları nasıl aldıklarını ve karlarını nasıl en uygun bir şekilde uygulanmasını sağlayabileceklerini anlamak için önemli bir kavramdır. Tedarik zincirinde üretim fonksiyonu farklı girdi seviyelerini kullanarak üretilebilecek maksimum çıktı miktarını gösteren matematiksel bir denklem veya grafik şeklin gösterilmesini sağlamaktadır.

Üretim fonksiyonu, bir firma için en uygun üretim seviyesini, yani kârı maksimize eden çıktı seviyesini belirlemek için kullanılabilir. Bu seviyeyi bulmak için, bir firma girdilerin maliyetlerini (işçilik ve malzeme gibi) üretilen çıktıdan elde edilen gelire karşı dengeleyebilmektedir. Firma, en uygun üretim seviyesini belirlerken piyasa talebi ve rekabet gibi faktörleri de dikkate alması gerekmektedir.

Üretim fonksiyonu ile işletmeler için önemli bir rol oynamaktadır. Tedarik zincirinde üretim fonksiyonuyla birlikte işletmeler müşterinin istek ve ihtiyaçlarına uygun olan ürün ve hizmetlerin daha iyi bir şekilde sunulmasını sağlamak için girdiler ve çıktıları işletmenin verimlilik ve karlılığına uygun şekilde ve daha hızlı ve etkin kararların alınması ile kaynakların tahsis edilmesini sağlamaktadır. Bu sayede işletmeler üretim planlamasını yaparak daha çok fayda sağlanmasını amaçlamaktadır.

Üretim fonksiyonu, üretim verimliliğini analiz etmek için bir çerçeve sağlamanın yanı sıra, girdilerdeki değişikliklerin çıktıyı nasıl etkileyeceği konusunda tahminler yapmak için de kullanılabilir. Böylelikle üretimdeki girdilerin değişiklikleri ile işletmelerin sermaye yatırımında artış sağlarsa, çıktı seviyelerinin tahmin edilmesi içinde kullanılabilir. Bu sayede işletmeler almış oldukları makine ve ekipman gibi araçların arttırılmasıyla üretimin yüksek seviyelere çıkarılmasını sağlayabilmektedir.

1.1.3. Planlama Fonksiyonu

Planlama fonksiyonu, hedeflerin belirlenmesini, stratejilerin geliştirilmesini ve bunlara ulaşmak için gereken eylemlerin ana hatlarının çizilmesini içeren yönetimin temel bir bileşenidir. Planlama süreci, işletmelerin doğru yönde ilerlediklerinden ve gelecekteki zorluklarla başa çıkmaya hazır olduklarından emin olmaları için kritik öneme sahiptir.

Planlama fonksiyonu, işletmelerin başarıya ulaşması ve rekabetçi kalması için gereklidir. İşletmeler net hedefler belirleyerek ve bunlara ulaşmak için stratejiler geliştirerek kaynaklarını ve çabalarını doğru yöne odaklayabilirler. Bu, işletmelerin kaynaklarından en iyi şekilde yararlanmalarını ve gelecekteki zorlukların üstesinden gelmeye hazır olmalarını sağlamaya yardımcı olmaktadır.

Planlama ile işletmelerin ilerdeki hedef veya amaçlarına ulaşması için izlenecek olan yolların önceden belirlenmesini sağlamaktadır (Özgen ve Yalçın, 2006: 117). Böylelikle planlama, amaç ve hedeflere ulaşılmasında başarı sağlayarak en iyi yolların belirlenmesini sağlamaktadır (Akmüt vd., 2003: 65). Planlama ile organizasyonun amaç veya hedeflerini belirlemek, bu amaçlara ulaşılması için stratejileri geliştirmek, faaliyetlerin bütünleşme ve koordine olması için geniş çaplı planlar hiyerarşisini geliştiren bir süreç olmaktadır (Robbins ve Decenzo, 2004: 78).

İşletmelerin faaliyete başlamadan önce zaman ve özellikle parayı ciddi bir şekilde planlaması gerekmektedir (Safranski ve Kwon, 1991: 4). Bu sayede hem zamanında işlemlerin yapılmasını hem de para kaynağının doğru bir şekilde kullanılmasını sağlayarak işletmenin kar elde etmesini sağlamaktadır.

Bir işletmenin başarılı olabilmesi günümüzde yeni fırsatların, yeni bilgilerin ve teknolojilerin olması için ilk adım olan planlamaya sahip olması gerekmektedir (Safranski ve Kwon, 1991: 5). Planlama ile birlikte amaçların gerçekleşmesini, rekabetin ortaya çıkardığı performansı ve planlama sisteminden dolayı tatmin düzeyini ifade etmektedir (McLarney, 2003: 422).

Planlama fonksiyonu ile taleplerin tahmin edilmesi, üretim programlarının belirlenmesi ve envanter seviyelerine karar verilmesini içermektedir. Böylelikle tedarik zincirinin her bir halkasında oluşabilecek aksaklıkların azaltılmasını sağlayarak verimliliğin üst seviyelere çıkmasına olanak tanınması sağlanabilmektedir.

1.1.4. Sipariş Fonksiyonu

Sipariş fonksiyonu, tedarikçilerden mal ve hizmet siparişi vermeyi içermesinden dolayı tedarik zinciri sürecinin kritik bir bileşenidir. Sipariş fonksiyonu işletmelerin ihtiyaçlarına ve sektörel ihtiyaçlara bağlı olarak değişebilmektedir. Bu değişiminin olmasıyla işletmeler siparişleri için kendilerine uygun olan tedarikçilerle birlikte çalışmalarını sağlamaktadırlar.

Sipariş fonksiyonundaki ilk adım siparişin oluşturulmasıdır. Sipariş oluşturulduktan sonra, işletmenin siparişi yerine ulaştırmak için uygun bir tedarikçi seçmesi gerekmektedir (Das, 2020). Bu şekilde potansiyel tedarikçilerin itibarlarını, kalite standartlarını, teslimat sürelerini ve fiyatlandırma gibi faktörlere göre değerlendirilmesi gerekmektedir (Wu & Weng, 2010). Böylelikle gerekli mal veya hizmetlerin miktarının, fiyatının ve diğer önemli ayrıntılarının belirtilmesini gerektirmektedir.

Uygun bir tedarikçi seçildikten sonra sipariş verilmektedir. Bu siparişin miktar ve teslimat tarihi gibi ayrıntılarının yanı sıra ödeme koşulları veya teslimat talimatları gibi diğer gerekli bilgilerin sağlanması gerekmektedir. Siparişin zamanında ve gerekli kalite standartlarında teslim edilmesini sağlamak için ilerlemesinin takip edilmesi gerekmektedir (Bryan & Srinivasan, 2014). Bu takip sayesinde siparişin üretim, sevkiyat ve teslimat gibi tedarik zincirinin çeşitli aşamalarında izlenmesini kolaylaştırmaktadır.

Sipariş fonksiyonu, işletmelerin ihtiyaç duydukları mal ve hizmetleri, ihtiyaç duyulan zamanda ve doğru fiyatla alınmasını sağlamak için kritik öneme sahip olmaktadır. İşletmeler planlanmış bir sipariş süreci izleyerek hata, gecikme ve tedarik zincirinin verimliliğini ve etkinliğini etkileyebilecek diğer sorun ve riskleri en aza indirilmesini sağlamaktadır. İşletmeler, sipariş sürecini optimize ederek ve tedarikçilerle uygun fiyat pazarlığı yaparak maliyetlerden tasarruf edebilmekte ve kârlılıklarını artırabilmektedirler.

Siparişlerin zamanında ve gerekli kalite standartlarında teslim edilmesini sağlayarak işletmeler müşteri memnuniyetini artırabilir, bu da sadakatin artmasına ve işlerin tekrarlanmasına yol açabilmektedir. Böylece etkin tedarik zinciri ve sipariş fonksiyonunun işlem sürecinin tasarımı finansal performansı artırmakta, işletmeler kendi sektör ve ürünlerine uygun bir performans kriteri baz alarak sürekli olarak izleme ve ölçümler yapması gerekmektedir (Shapiro, vd., 1992).

1.1.5. Stok Yönetimi Fonksiyonu

Stok yönetimi, fiziksel ürünler veya envanterle ilgilenen her işletme için önemli bir noktadır. Bir işletmenin stoklarında bulunan ürünlerin takip edilmesi, tedarik zinciri boyunca mal akışının yönetilmesi ve stok tüketimlerinin veya aşırı stoklanmanın önlenmesi için envanter seviyelerini optimize edilmesini sağlamaktadır (Vidal, vd., 2019).

Etkili stok yönetimi, bir işletmenin maliyetlerini kontrol edilmesini sağlarken, kârı maksimize etmekte ve müşteri talebini karşılanmasını sağlamaktadır. Böylelikle gereksiz israfın azaltılmasının, depolamanın ve taşıma maliyetlerinin en aza indirilmesinin ve müşterilerin ihtiyaç duyduklarında ürünlerin her zaman mevcut olmasını sağlamaya yardımcı olmaktadır (Parveen, vd., 2012). Bu sayede işletmeler sürdürülebilir kazanç elde edebilmektedir.

Stok yönetimi, stok seviyelerinin, satış verilerinin, tahminlerin, sipariş durumu, üretim ve dağıtım planlarını ve performans ölçümlerini yapabilmesi için müşterilerle olan sürekli bilgi akışının sağlanması gerekmektedir (Efrilianda, vd., 2018). Bu sayede stok yönetimi daha hızlı ve etkin bir şekilde sürdürülebilirliği arttırmaktadır.

Stok yönetiminin faydaları;

- Müşteriye sunulmakta olan hizmet seviyesinin artması,
- Satışların artması,
- Karlılığın sürekliliği,
- Teslimat süresinin kısaltılması,
- Stoklarda maliyeti düşüklüğü,
- Talep tahminin kolay yapılabilmesi,
- Siparişlerin izlenmesini sağlayarak, fazla stoğun azaltılmasını sağlamaktadır.

Stok maliyetlerini ve ürün maliyetlerini oluşturan giderler içerisinde büyük bir paya sahip olması, gerekse üretimin plana uygun olarak kesintiye uğramadan yapılabilmesinden dolayı talebin zamanında karşılanmasında oynadığı rol itibarıyla, bir üretim yöneticisi açısından en önemli sorumluluk alanından biri de stok yönetimi olmaktadır (Top, 2006: 191).

Hizmetlerin sürekli devam etmesi açısından zorunlu bulunmakta olan malzeme ve hammaddenin depo edilmesi, temin edilmesi, işlenmesi ve üretimi yapılmış olan ürünleri

alıcılara ulaşması aşamasında depolanması, lojistik faaliyetlerini organize edilebilmesi, kontrol altında tutulması ve yürütülmesini sağlayan bir süreçtir (Küçük, 2017).

1.1.6. Depolama Fonksiyonu

Depolama fonksiyonu, ürünleri depolamak için kullanılan fiziksel alan ve ekipmanın yönetimini içermekte ve bunların güvenli ve düzenli bir şekilde tutulmasını sağlamaktadır. Böylelikle üretilen mal ve hizmetlerin nihai varış yerlerine taşınmasından önce depolanmasını sağlamaktadır. Etkili depolama, etkili envanter yönetiminin yanı sıra verimli depolama ve taşıma tekniklerinin kullanılmasını gerektirmektedir.

Depolama yönetimi malların hasar, hırsızlık ve bozulmaya karşı korunmasını sağlayarak kayıpları azaltır ve maliyetleri en aza indirir. Bu sayede depolama yönetimi, mevcut depolama ekipmanının kullanımını en üst düzeye çıkararak ve ek depolama alanının ihtiyacını azaltarak alanın optimize edilmesine yardımcı olabilmektedir.

Depolama yönetimi satın alma, üretim ve satış konularında bilinçli kararlar almak için kullanılabilir veriler sağlamaktadır. Bu sayede tedarik zincirinde depolama, bir kuruluşun kaynaklarını verimli bir şekilde kullanmasına yardımcı olduğu için kritik öneme sahiptir.

İşletmeler, malzemeleri daha düşük fiyatlarla temin edebildikleri ve depolayabildikleri zaman satın alma işlemlerinden tasarruf edebilmektedir. Depolanan malzemeler ayrıca teslimat için bekleme süresinin kısılmasına yardımcı olur ve tedarik zincirinde aksama olasılığını azaltmaktadır. Bu da verimliliğin artmasına ve işletmenin hedeflerine ulaşmasına yardımcı olmaktadır. İşletmeler depolama yönetimlerini optimize edebilir ve daha fazla verimlilik ve kârlılık elde edebilmeyi sağlamaktadır.

Tedarikte depolama, malların teslim edilmesi için geçen süre olan teslim süresini önemli ölçüde azaltabilmektedir. Stoklarında malzeme bulunduran bir işletmenin, tedarik için beklemek zorunda kalmadan acil ihtiyaçlarını karşılayabilmektedir. Bu, işletmenin mal ve hizmetleri hızlı bir şekilde üretebildiği için üretkenliği ve operasyonel verimliliğini artırmaya yardımcı olmaktadır.

İşletmeler malzemeleri düşük fiyatlarla temin edip depolayarak tedarikten tasarruf edebilir, teslim süresini kısaltabilir, nakit akışını iyileştirebilir ve tedarik zinciri risklerini

azaltabilmektedir. Böylece işletmenin herhangi bir kayıp yaşamaması için sağlıklı depolama sistemini oluşturması zorunlu olmaktadır (Orhon, 2003).

1.1.7. Envanter Fonksiyonu

Etkin envanter yönetimi sağlamak ve aşırı stoklama nedeniyle gereksiz maliyetlerden kaçınmak için, doğru zamanda doğru miktarda ürün bulundurmak amacıyla envanter seviyelerini optimize etmek çok önemlidir (Priniotakis & Argyropoulos, 2018). Bu da doğru talep tahmini, gerçek zamanlı envanter takibi ve farklı paydaşlar arasında etkili iletişim gerektirir. Tedarik zincirinin yönetilmesinde bir diğer önemli faktör de envanter seviyelerinin optimize edilmesidir (Li, vd., 2014). Çok fazla envanter değerli kaynakları bağlayabilir ve maliyetleri artırabilirken, çok az envanter stokların tükenmesine ve satış kaybına neden olabilmektedir. İşletmeler, envanter seviyelerini dikkatli bir şekilde yöneterek ve tam zamanında envanter uygulamalarını hayata geçirerek israfı azaltabilir, maliyetleri düşürebilir ve müşteri memnuniyetini artırabilmektedir.

Envanter fonksiyonu ihtiyaç duyulduğunda doğru ürünlerin mevcut olmasını sağlamak için envanter seviyelerinin yönetimini içermektedir. Etkili envanter yönetimi, envanter tutmanın maliyetini stok tükenmesi riskine karşı dengelemek için tahmin, talep planlama ve envanter kontrol tekniklerinin kullanılmasını gerektirir. Envanter fonksiyonu, perakendeciler, üreticiler ve distribütörler gibi fiziksel ürünlere dayanan işletmeler için kritik öneme sahip olmaktadır. İşletmelerin ellerinde bulunan malların yanı sıra değerlerini ve konumlarını takip etmelerini sağlamaktadır. Bunu yaparak şirketler, talebi karşılamak ve israfı en aza indirmek için stok seviyelerini optimize edebilmektedir.

Envanter işlevi, bir şirketin stok seviyelerini satın alma noktasından satış noktasına kadar yönetme sürecini ifade eder. İşletme yöneticisinin envanter yönetimi, hammaddeyi nihai ürüne dönüştürme ve bu ürünün son tüketiciye ulaşımını sağlama süreçlerinin envanter kontrolünü planlamak gibi hayati görevlerden biridir (Fıçıcı, 2006, s. 11). Malların veya ürünlerin depolanması, izlenmesi ve hareketinin yanı sıra envanter seviyelerinin izlenmesini ve gerektiğinde stokların yeniden sıralanmasını içerir.

Etkili envanter yönetimi, bir işletmenin başarısı için çok önemli bir konumda yer almaktadır. Müşteri memnuniyetinden nakit akışına kadar her şeyi etkileyebilmekte ve bu durumda dikkatli ve planlı olarak yapılması gereken önemli bir fonksiyon haline getirmektedir.

1.1.8. Dağıtım Fonksiyonu

Dağıtım fonksiyonu, mal ve hizmetlerin müşterilere teslim edilmesini içermektedir. Etkili dağıtım, verimli süreçler, etkili nakliye, lojistik ve operasyonları optimize etmektedir. Ürünlerin üreticiden veya tedarikçiden son kullanıcıya veya müşteriye ulaştırılması sürecini ifade etmektedir. Dağıtım fonksiyonu, ürünlerin müşterilerin ihtiyaç duydukları anda ellerinde olmasını ve iyi durumda ulaşmasını sağlamak açısından kritik önem taşımaktadır.

Tedarik zinciri alanında dağıtım fonksiyonu, mal ve hizmetlerin nasıl dağıtılacağına belirlenmesinde kritik bir rol oynar. Dağıtım fonksiyonu mal ve hizmetlerin tedarikçiden tüketiciye taşınması sürecini ifade eder. Tedarik zincirinde dağıtım fonksiyonu, tedarikçilerden dağıtım merkezlerine olan satın alma döngüsü, dağıtım merkezlerinde depolara olmakta olan akış sipariş döngüsü, depolardan da perakendecilere olan akışın ikmal döngüsü olarak tanımlanmaktadır (McClain vd., 1992). Böylece mal ve hizmetlerin müşteriye zamanında ve verimli bir şekilde teslim edilmesini sağlama konusunda önemli bir rol oynamaktadır.

Kaliteyi ve müşteri memnuniyetini korurken maliyetleri kontrol etmek zor olabilmektedir. Tedarik zincirinde bir taşıma modu seçerken nakliye maliyetleri, teslimat süreleri ve taşıma kapasitesi gibi faktörleri göz önünde bulundurması önemli olmaktadır.

Dağıtım süreci boyunca müşterilere destek ve yardım sağlamayı içerir. Sorulara yanıt vermeyi, sorunları çözmeyi ve müşteri memnuniyetini sağlamayı içerir. Ürünlerin iyi durumda teslim edilmesini sağlamak müşteri memnuniyeti açısından kritik önem taşır. Kalite kontrol sorunları nakliye, depolama veya sipariş karşılama sırasında ortaya çıkabilir ve hasarlı veya kusurlu ürünlere yol açabilmektedir. Bu durumda dağıtım fonksiyonu bakım ve servis hizmetlerini de sağlayarak doğrudan müşteri memnuniyetinin artırılmasına yardımcı olmaktadır.

Etkili dağıtım ayrıca sağlam izleme ve raporlama mekanizmaları gerektirir. Bu, kuruluşların tedarik süreçlerini izlemelerini ve iyileştirme için potansiyel alanları belirlemelerini sağlar. Kuruluşlar teslimat süreleri, sipariş doğruluğu ve tedarikçi performansı gibi satın alma metriklerine ilişkin verileri analiz ederek satın alma süreçlerini iyileştirmek için veriye dayalı kararlar alabilirler.

1.1.9. Müşteri Hizmetleri

Müşteri ilişkilerinin yönetilmesini, soru ve şikayetlerin ele alınmasını ve tedarik zinciri süreci boyunca müşteri ihtiyaçlarının karşılanmasının sağlamaktadır.

Tedarik zincirinde müşteri hizmetlerinin rolü, tedarikçilerle olumlu ve profesyonel bir ilişki sürdürürken kuruluşun tedarikteki hedeflerine ulaşılmasını sağlamak açısından çok önemli rol oynamaktadır. Böylelikle tedarik zincirinde müşteri hizmetlerinin birincil amacı, tedarikçilerini mutlu, memnun ve işletmelerin satın alma ihtiyaçlarını karşılamak ve müşterilerin gereksinimlerini sağlamak için sürdürülebilir olmalarını sağlamaktır. Müşteri hizmetleri temsilcileri, kuruluş ile tedarikçileri arasında bir arayüz görevi görerek ilişkinin mümkün olan en verimli ve etkili şekilde yönetilmesini sağlamaktadır. İhtiyaçlarını anlamak ve gereksinimlerinin zamanında ve uygun maliyetli bir şekilde karşılanmasını sağlamak için tedarikçilerle yakın bir şekilde çalışılmasını sağlamaktadır.

Tedarik zincirindeki müşteri hizmetleri, iç paydaşlardan gelen satın alma süreci, tedarikçi bilgileri, ürün stoğu ve teslimat programları ile ilgili soruları en hızlı bir şekilde yanıtlamasından sorumlu olmaktadır. Bu sayede müşterileri siparişlerinin durumu hakkında bilgi almasını sağlamaktadır. Müşteri hizmetleri ekipleri siparişlerin takibinde, güncellemelerin sağlanmasında ve tedarik süreci boyunca şeffaflığın sağlanmasında çok önemli bir rol oynamaktadır. Müşteri hizmetleri, tedarik sürecinde ortaya çıkabilecek çeşitli sorunları ele alır ve çözüm üretmektedir. Bunlar arasında sipariş tutarsızlıkları, teslimat gecikmeleri, ürün kalitesi endişeleri veya faturalama tutarsızlıkları yer alabilir. Bu sebeplerden dolayı müşteri hizmetlerinin tedarik zincirindeki önemi ve yeri işletmeler açısından çok önemli bir konumda olmaktadır. İşletmeler müşteri hizmetleri sayesinde verimli, etkin ve hızlı bir şekilde işlemlerini yaparak müşterilerine ve tedarikçilerine memnun olmalarını sağlayarak kar elde edilmesini de sağlamaktadır.

Tedarik zinciri müşterilere en hızlı, kaliteli ve işlevsel ürünleri sağlamak amacıyla müşterilerle iletişim kurulmasına olanak tanımaktadır. Ürünlerinin temin edilmesi, yüklenme süreleri ve siparişlerin durumlarını izleme gibi konularda müşterileri bilgilendirmede birinci elden kaynak olma hizmeti sunmaktadır. (Özdemir, 2004: 92).

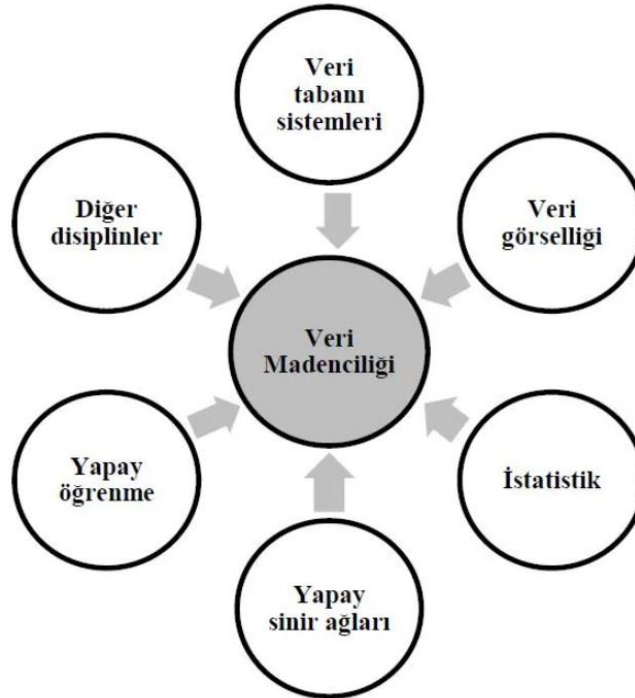
İKİNCİ BÖLÜM

VERİ MADENCİLİĞİ NEDİR?

Günümüzün dijitalleşen dünyasında, üretilen veri miktarı daha önce görülmemiş bir hızla artmaktadır. Dijital bilginin katlanarak büyümesiyle birlikte, geniş veri kümelerini anlamlandırma ihtiyacı veri madenciliği alanının doğmasına neden olmuştur. Çevrimiçi aktivitelerden ve sosyal medya etkileşimlerinden sensör verilerine ve sağlık kayıtlarına kadar büyük bir bilgi bolluğu ortaya çıkmaktadır. Bu veri tufanının ortasında, inovasyonu teşvik edebilecek, karar alma süreçlerini geliştirebilecek ve sektörlerde devrim yaratabilecek değerli içgörülerini ortaya çıkarmak için kullanılmayan bir potansiyel yatmaktadır. Büyük veri kümelerinden anlamlı örüntüler, ilişkiler ve eğilimler çıkarmak için çok gelişmiş teknikler ve algoritmalarla donanmış veri madenciliği burada devreye girmektedir.

Linden (1999)'e göre veri keşfi, istatistiksel ve matematiksel teknikler ile desen tanıma teknolojilerinin uygulanmasıyla, depolardaki büyük hacimdeki birikmiş verilerin analiz edilmesi ile yeni anlamlı ilişkiler, motifler ve eğilimler ortaya çıkarma sürecidir (Larose, 2005, s. 2).

Şekil-8: Veri madenciliği ve disiplinler



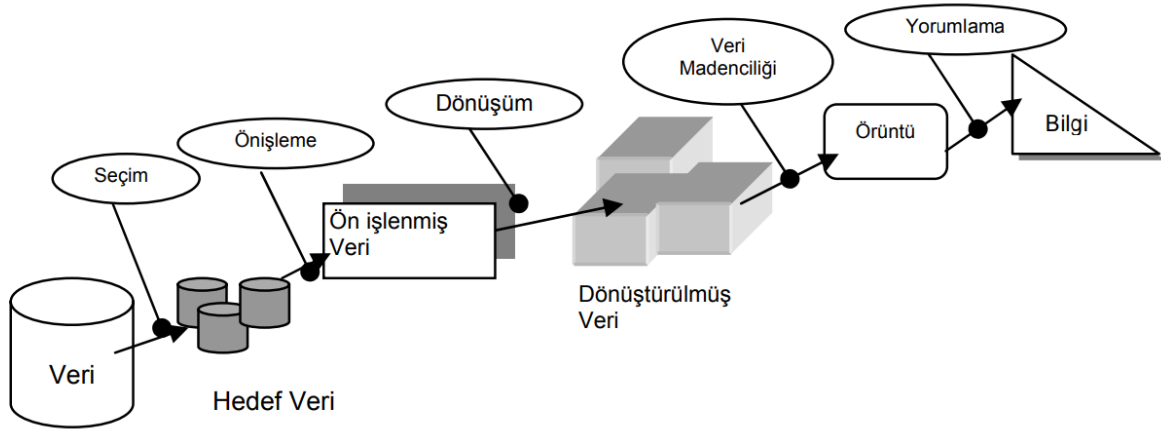
Kaynak: Savaş, 2020.

Veri madenciliği sayesinde devasa veri yığınları içindeki saklı bilgilerin ortaya çıkarılması sağlanmaktadır. Bu süreç, istatistik, matematik alanları, modelleme yöntemleri, veri tabanı teknolojileri ve çeşitli yazılım araçları kullanılarak gerçekleştirilir (Baykal, 2006, s. 96). Veri madenciliği genel olarak; büyük hacimli verilerden anlamlı bilgilerin çıkartılması ve çeşitli yöntemler kullanılarak işlenebilmesi ve yorumlanabilir hale getirilmesidir (www.beyaz.net). Böylece işletmelerin ve kuruluşların verilerini analiz etmeleri ve bilinçli kararlar almaları için hayati bir araç haline gelmiş olmaktadır.

Veri madenciliği, büyük veri kümelerinden yararlı veya ilginç bilgiler çıkarma işlemidir. İstatistik, makine öğrenimi ve veri tabanı sistemleri gibi çeşitli alanlardan teknikleri bir araya getirerek karar verme sürecini yönlendirebilecek ve iş stratejilerini geliştirebilecek önemli bilgiler ortaya çıkarmaktadır. Bu veriler müşteri verileri, işlem verileri, sosyal medya verileri ve web verileri gibi çeşitli kaynaklardan gelebilir.

Veri madenciliği, veri tabanı teknolojisi, istatistik, makine öğrenimi, yüksek performanslı hesaplama, örüntü tanıma, sinir ağları, veri görselleştirme, bilgi alma, görüntü ve sinyal işleme ve uzamsal veri analizi gibi birçok disiplinden tekniklerin entegrasyonunu içerir.

Şekil-9: Veri madenciliğinin veri işleme süreci içindeki yeri



Kaynak: Han, Kamber, 2001.

Veri madenciliğinin birincil amacı, ham verileri eyleme geçirilebilir bilgilere dönüştürerek kuruluşların veriye dayalı kararlar almasını, rekabet avantajı elde etmesini ve operasyonel verimliliği artırmasını sağlamaktır. Veri madenciliğinde veriler seçilir, temizlenir, bütünleştirilir, değerlendirilir ve sunularak verinin en son çıktısından bilgi çıkarımı yapılmaktadır (Koçarslan, Gedik ve Koçak). Bu sayede keşfedilmiş olan bilgiyle karar verme, bilgi yönetimi, süreç kontrolü, sorgu işleme gibi vb. alanlarda da uygulanabilmektedir. Böylece

veri madenciliği, veri tabanları sistemlerinde bulunan en önemli sınırlardan biri ve bilgi endüstrisi içerisindeki en umut vericisi, yeni veri tabanı uygulamaları olaraktan kabul edilebilmektedir.

Dijital teknolojilerin gelişmesinin sonucunda kapasite seviyelerinde üst düzey işlem yapabilme gücünde ucuzlama olmuş, depolama ünitelerindeki veri saklama kapasitesi gelişmiş ve daha kolay hale gelmiş olmaktadır. Böylece verilerde kıtlık durumu ortadan kalkmış ve daha çok veri ortaya çıkmıştır. Bu durum bilgiye erişim konusundaki endişenin yerini artık erişim sağlanabilen miktarlarla başa çıkma endişesini ortaya çıkarmıştır (Usama & Paul, 1997).

Dijital ortam gelişmeye devam ettikçe, veri madenciliğinin gücünden yararlanmak, veri odaklı çağda rekabet avantajı ve sürdürülebilir büyüme arayan kuruluşlar için çok önemli olmaktadır. Sorumlu veri kullanımı ve etik hususlar göz önünde bulundurulduğunda, veri madenciliği sektörlerde devrim yaratma, inovasyonu teşvik etme ve dijital çağda yaşam kalitemizi artırma potansiyeline sahiptir.

Veri madenciliğinin uygulama alanları:

1. İş Zekası: Veri madenciliği, kuruluşların müşteri davranışlarını analiz etmesini, pazar eğilimlerini belirlemesini ve operasyonları optimize etmesini sağlayarak iş zekasında hayati bir rol oynar. İşletmelere müşteri segmentasyonu, satış tahmini, dolandırıcılık tespiti ve kişiselleştirilmiş pazarlama gibi alanlarda yardımcı olur.
2. Sağlık hizmetleri: Veri madenciliği, sağlık hizmeti sağlayıcılarının elektronik sağlık kayıtlarından, klinik deneylerden ve tıbbi araştırmalardan değerli bilgiler çıkarmasını sağlar. Hastalık tahmininde, hasta teşhisinde, tedavi optimizasyonunda ve potansiyel ilaç etkileşimlerinin keşfedilmesinde yardımcı olur.
3. Finans ve Bankacılık: Veri madenciliği, finans kurumlarına dolandırıcılık faaliyetlerini tespit etmede, riskleri yönetmede ve borsa eğilimleri, müşteri kredibilitesi ve kredi temerrütleri ile ilgili doğru tahminlerde bulunmada yardımcı olur.
4. E-ticaret ve Perakende: Veri madenciliği teknikleri, e-ticaret platformlarının ve perakendecilerin müşteri tercihlerini analiz etmelerini, ürün önermelerini, fiyatlandırma stratejilerini optimize etmelerini ve tedarik zinciri yönetimini iyileştirmelerini sağlar.

5. İşletme ve Pazarlama: Veri madenciliği, işletmelerin müşteri davranışları, tercihleri ve eğilimleri hakkında içgörü kazanmasını sağlar. Müşteri memnuniyetini artırmak ve gelir artışını sağlamak için hedefli pazarlama kampanyalarına, kişiselleştirilmiş önerilere ve pazar analizine yardımcı olur.
6. Üretim ve Kalite Kontrol: Veri madenciliği teknikleri kusurları belirlemek, üretim süreçlerini optimize etmek ve ürün kalitesini artırmak için kullanılır. Kestirimci bakımı mümkün kılarak arıza süresini ve maliyetleri azaltır.

İşletmelerin veya kuruluşların satışlarında artışlar ve müşterilerin işlemleriyle ilgili bilgilerden daha fazla kar elde etmelerinde yardımcı olan yüksek potansiyelli güce sahip bir araç olmuştur. Veri madenciliği aynı zamanda raporların ve sorguların işletmelere sağlayamadığı yararlı bilgileri sağlamaktadır.

Verilerin daha anlamlandırılabilir bir hale gelebilmesini sağlamak için veri entegrasyonun yapılması gerekmektedir. Veri entegrasyonu farklı iş yapılarından gelen istatistikleri bir araya getirerek ortak bir birleştirme sağlamaktadır. Böylelikle ortak bir veri deposu ortaya çıkmaktadır. Örneğin, müşterinin alışveriş yaptığında ortaya çıkan bilgiler şunlardır; satış, fatura ve pazarlamadan oluşan farklı iş yapılarıdır ve bu bilgiler sayesinde her bir tüketicinin bilgilerinin çıkarılmasıyla birlikte müşteri desteğinin sağlanması, raporlama ve analiz için kullanılması durumunda müşteriye ait tek bir görünüm ortaya çıkarılması sağlanılmaktadır.

Veri madenciliğinde verilerin saklandığı depolar veya ambarlar bulunmaktadır. Bu depolar çeşitli teknolojik cihazlardan gelen kayıtların tutulmasını ve analizler yapılmasını sağlamaktadır. Veri depolarının amacı ise şirketlerin faaliyetleri hakkında faydalı bilgiler sağlamak ve analizlerin yapılabilmesi için bir veri hazinesi oluşturmaktadır. Böylece verilerin, bir bilgisayar tarafından işlenmesini sağlaması için sayılar, metinler veya gerçek hayattaki verilerdir. Bunlar; satışlar, fiyatlar, bordrolar ve muhasebeler gibi matematiksel veriler şeklinde olabilmektedir. Bu verilerin veri ambarlarında saklanması işletmelere hem faydalı bilgiler açısından hem de rekabet üstünlüğünün sağlanması açısından büyük önem taşımaktadır. Çünkü bu veriler sayesinde işletmeler ne kadar kar elde ettiklerini, pazar paylarını ve müşteri istek ve ihtiyaçlarına uygun ürünlerin veya hizmetlerin kısa sürede karşılanması için çözüm oluşturmak için analizler yapılmasını sağlamaktadır.

Veri madenciliğindeki süreçler (Sadiku, Shadare & Musa, 2015: s. 510);

1. Verimli verilerin depolanması ve verilerin işlenebilir olması

2. Araştırılacak olan değişkenlerin sayılarına karar verilmesi
3. Verilerin görselleşebilir ve özetlenebilir olması
4. Korelasyon, standart sapma, ortalama ve yüzdelik dilimler gibi istatistiksel ölçümlerin uygulanabilir olması
5. Analiz yöntemleri olarak regresyon, k-en yakın komşu metodu (nearest neighbor methods) ve k- ortalama kümeleme yöntemi (k-means clustering) gibi yöntemlerin kullanılması

Veri madenciliği yoluyla faydalı bilgiler elde etmek için izlenebilecek bazı genel adımlar vardır bunlar:

1. Problemi tanımlama: Veri madenciliği yapılabilmesi için problemin amacını ve kapsamını net bir şekilde tanımlanması gerekmektedir. Verilerden ne tür bilgiler veya içgörüler elde edilmesini belirlemek gerekmektedir.
2. Veri toplama: Çeşitli kaynaklardan ilgili verilerin toplanmasını sağlamaktadır. Buna veri tabanları, veri ambarları, dosyalar, API'ler veya web kazıma dahil olabilmektedir. Verilerin doğru, eksiksiz ve çözmeye çalışılan sorunu temsil eder nitelikte olduğundan emin olunması gerekmektedir.
3. Veri ön işleme: Analiz için kalitesini ve uygunluğunu sağlamak üzere verileri temizleyin ve ön işleme yapılmasını sağlamak gerekmektedir. Bu adım eksik değerlerin, aykırı değerlerin, veri normalizasyonunun, veri dönüşümünün ve özellik seçimi veya mühendisliğinin ele alınmasını içerebilmektedir.
4. Veri entegrasyonu: Birden fazla veri kümesiyle çalışılması durumunda, bunları tek bir uyumlu veri kümesine entegre edilmesini sağlamaktadır. Bu, ortak özneliklere veya anahtarlaraya dayalı olarak farklı veri kümelerinin birleştirilmesini içerebilmektedir.
5. Keşifsel veri analizi (EDA): İçgörü kazanmak ve kalıpları veya eğilimleri belirlemek için verilerin ilk keşfini gerçekleştirmektedir. Grafikler, çizelgeler veya özet istatistikler kullanarak verileri görselleştirilmektedir. Bu adım, veri dağılımının anlaşılmasına ve değişkenler arasındaki potansiyel ilişkilerin belirlenmesine yardımcı olmaktadır.
6. Veri madenciliği teknikleri seçme: Problemin hedeflerini ve verilerin niteliğine göre uygun veri madenciliği tekniklerinin seçilmesini sağlamaktadır. Yaygın teknikler arasında sınıflandırma, regresyon, kümeleme, birliktelik kuralı ve

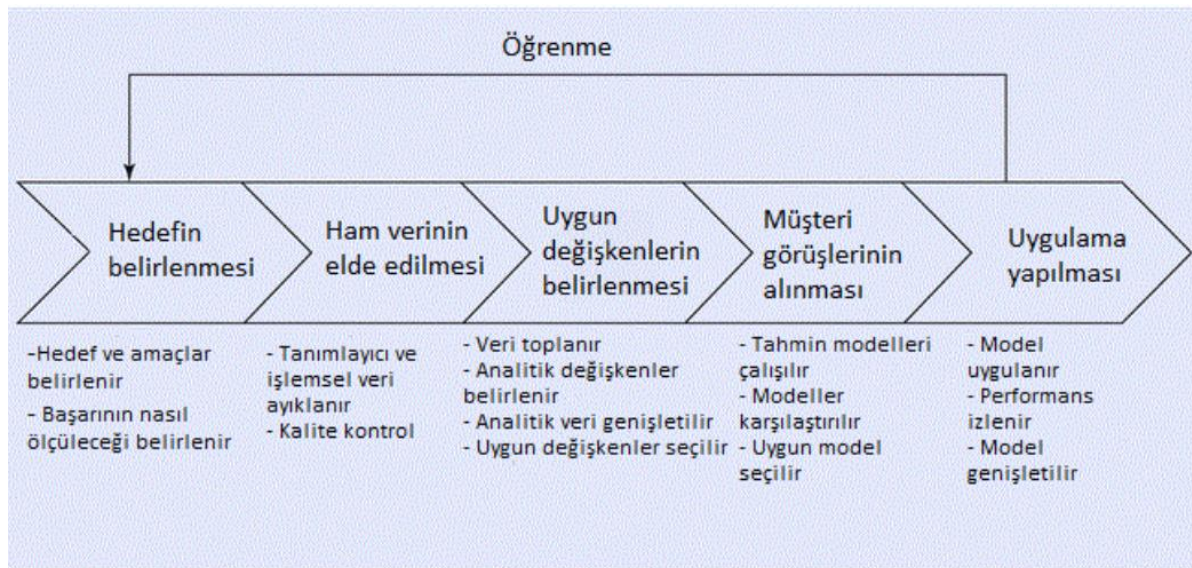
anomali (aykırı deęer) tespiti yer almaktadır. Doğru tekniklerin seçilmesi, sorunun türüne ve mevcut verilere baęlı olmaktadır.

7. Veri madencilięi algoritmalarını uygulama: Seçilen algoritmaları hazırlanan veri kümesine uygulanmasını sağlamaktadır. Bu süreç, modellerin eğitilmesini, algoritmaların uygulanmasını ve verilerden kalıpların veya ilişkilerin çıkarılmasını içermektedir.
8. Sonuçları deęerlendirme ve doğrulama: Veri madencilięi modellerinin performansını ve kalitesini deęerlendirilmesini sağlamaktadır. Modellerin performansının doğruluęunu, kesinlięini, geri çağırmasını veya dięer ilgili ölçümlerini ölçmek için uygun deęerlendirme metriklerini ve tekniklerini kullanılmasını sağlamaktadır.
9. Sonuçları yorumlama ve görselleştirme: Elde edilen modellerin, ilişkileri veya içgörülerin anlamlı bir şekilde yorumlanabilmesini sağlamaktadır. Sonuçları anlama ve iletişimi kolaylaştırmak için çizelgeler, grafikler veya dięer görsel temsiller kullanılarak görselleştirmektedir.
10. Bulguları dağıtmak ve entegre etmek: Çıkarılan bilgileri pratik kullanıma uygulanması sağlanılmaktadır. Bu, sonuçların bir iş sürecine, karar verme sistemine entegre edilmesini veya elde edilen içgörülere dayalı olarak eyleme geçirilebilir öneriler oluşturulmasını içerebilir olmaktadır.
11. İzleme ve güncelleme: Uygulanan modellerin performansını sürekli olarak izlenmesi ve gerektiğinde güncellenmesi gerekmektedir. Veri madencilięi yinelemeli bir süreçtir ve geri bildirimlere ve yeni verilere dayalı olarak modelleri iyileştirmek ve geliştirmek önemli olmaktadır.

Veri madencilięinde bu adımlar izlenerek çalışmalarda etkili bir şekilde faydalı bilgiler elde edilmesi mümkün olmaktadır. Veri madencilięi yöntemi ile veriler daha aktif bir şekilde kullanılarak analizler yapılması sağlanılmaktadır. Böylelikle veriler daha anlamlı ve işe yarar hale gelmektedir.

Veri madencilięi, verileri arıtır, birleştirir, ayıklar, dönüştürür, analiz eder ve sunar; bu sayede verinin nihai biçiminden bilgi elde etmektedir. Böylelikle veriler daha anlamlı ve faydalı hale gelmektedir. Veri madencilięi asıl olarak bilgisayar destekli bir bilgi işleme yöntemi olarak kullanılmaktadır (Vranic vd., 2007).

Şekil-10: Veri Madenciliği Süreci



Kaynak: Kumar, Reinartz, 2018.

Veri madenciliğinde kullanılan teknikleri anlamak, işletmelerin günümüzün veri odaklı ortamında daha verimli ve rekabetçi olmalarına yardımcı olabilmektedir. Böylelikle günümüz işletmeler açısından veri madenciliği önemli bir konudur.

Veri madenciliğinde verilerden anlamlı sonuçlar çıkarılması işletmelerin müşteri edinimini, müşteri bölümlenmesini, müşterinin elde tutulmasını, ayrılma eğilimini gösteren müşterinin profilinin ortaya konulması, müşteri değerlendirme, müşterinin davranışları ve eğilimini belirleme, kredi derecelendirmesi ve pazar sepetinin analizi gibi daha birçok müşteri odaklı uygulamalardan girdiler ortaya çıkmaktadır (Ersöz, 2019: 17). Bu sayede işletmeler bu verileri birleştirerek faydalı bilgilerin ortaya konulmasını ve kararlar alınmasını sağlamaktadır.

Veri madenciliği sayesinde bir işletme; kendi müşterisini olan fakat rakibine gitmesi durumunda müşterilerle ilgili analiz yaparak rakiplerini tercih etmekte olan müşterilerinin özelliklerini elde edebilmekte ve bu veriden yola çıkarak gelecek senelerde kaybetme olasılığından dolayı müşterilerin kimler olabileceğini tahminler yaparak bulmakta ve onları kaybetmemek, kaybettiği zamanda geri kazanmak için stratejiler geliştirmektedir (Chen, Sakaguchi ve Frolick, 2006: 1-6).

Verileri toplama ve saklamadaki kolaylık, veri tabanı yönetim sistemlerinde olan teknolojik gelişmeler, bilgi işlem maliyetinde oluşan düşüşlerle birlikte kullanılacak analitik araçların artmasındaki veri madenciliği uygulamalarında olan ilgiyi arttırmaktadır (Park, Piramuthu ve Shaw, 2001: 205-222). Böylelikle birçok veri madenciliği uygulamaları

kullanılarak daha iyi kararlar alınmasında, verimlilikte ve sürdürülebilir işletmeler olma konusunda yardımcı olmaktadır.

Veri madenciliğinde kullanılmakta olan bazı programlar:

1. IBM SPSS Modeler (Clementine): SPSS Modeler, veri keşfi, görselleştirme ve modelleme yaparak kapsamlı çalışma sunarak kullanıcıların veri odaklı kararlar almasını ve karmaşık iş sorunlarını çözmesini sağlar. Clementine, karar ağaçları haricinde, faktör, regresyon analizleri gibi analiz yapılabilmesi ve yapay sinir ağlarının kullanılması ve veri tabanına kolaylıkla bağlanılabilen bir araçtır (Özyirmidokuz, 2009:70).
2. Weka: Weka, veri analizi, modelleme ve görselleştirme için geniş bir algoritma ve teknik yelpazesi sunan popüler ve çok yönlü bir açık kaynaklı veri madenciliği aracıdır. Weka, sınıflandırma, regresyon, kümeleme, birliktelik kuralı madenciliği ve özellik seçimi dahil olmak üzere geniş bir teknik nitelikleri kapsayan zengin bir makine öğrenimi algoritmaları kütüphanesi sunmaktadır.
3. SAS Enterprise Miner: SAS tarafından tasarlanan Enterprise Miner, veri keşfi, modelleme ve dağıtım için kapsamlı bir araç ve algoritma paketi sunmaktadır. Büyük veri kümelerindeki desenleri keşfetmek, sonuçları tahmin etmek ve veriye dayalı kararlar almak için kullanılmaktadır.
4. Statsoft Statistica Data Mining & Predictive Analytics: Gelişmiş analitik çözümlerinin lider sağlayıcısı Statsoft tarafından geliştirilen Statistica, veri keşfi, modelleme ve tahmine dayalı analiz için çok çeşitli araçlar, algoritmalar ve teknikler sunmaktadır. StatSoft Statistica, işletmelerin verilerini analiz etmelerine ve daha iyi iş kararları almalarına yardımcı olmak için tasarlanmış güçlü bir veri madenciliği ve tahmine dayalı analitik yazılımıdır.
5. Mozenda's Data Mining Software: Mozenda, kullanıcıların herhangi bir web sitesinden veya çevrimiçi kaynaktan veri çıkarmasına olanak tanıyan bir veri madenciliği yazılımıdır. Bu güçlü araç web sayfalarından, çevrimiçi veri tabanlarından ve diğer dijital kaynaklardan veri toplayabilmektedir. Veri toplama süreçlerini otomatikleştirmek, böylece iş akışlarını kolaylaştırmak ve kullanıcılara zaman kazandırmak için tasarlanmıştır.
6. RapidMiner: RapidMiner, veri keşfi, analizi ve görselleştirmesi için çeşitli araçlar sunan bir veri bilimi ve analitik platformudur. Kullanıcılar, kapsamlı kodlama becerileri gerektirmeden verileri içe aktarmaktan modellemeye ve

analitik çözümleri dağıtmaya kadar uçtan uca veri analizi yapabilmektedir. RapidMiner'in bir diğer önemli özelliği de iş akışlarını otomatikleştirme yeteneğidir. RapidMiner'ın Java, Python ve R gibi çeşitli programlama dillerini destekleyerek kullanıcıların özel modeller geliştirmesini veya platformu genişletmesini kolaylaştırmaktadır.

7. Tanagra: Tanagra, karmaşık veri kümelerini analiz etmek için çok çeşitli algoritmalar ve araçlar sağlayan güçlü bir açık kaynaklı veri madenciliği ve tahmine dayalı analitik yazılımıdır.
8. Oracle: Oracle, veri madenciliği gerçekleştirmek için kümeleme, sınıflandırma, anormallik tespiti, özellik çıkarma, regresyon analizi ve birliktelik kuralı madenciliğini içeren bir dizi algoritma sağlamaktadır. Bu algoritmalar çoğu işletme için günlük olarak çok sayıda veri üretir ve trendleri keşfetmek ve karar verme sürecini iyileştirmek için verilerini analiz ederek veri madenciliğinden yararlanabilmektedir. Oracle, veri ambarları, veri tabanları ve diğer kaynaklar gibi çeşitli kaynaklardan gelen verileri analiz edebilir ve kullanıcıların bilinçli kararlar almasına yardımcı olabilecek kalıpları ve eğilimleri keşfetmelerine yardımcı olabilmektedir.
9. Microsoft SQL Server –(Excel) Data Mining: Microsoft SQL Server Excel Veri Madenciliği, kurumların Microsoft SQL Server ve Excel kullanarak verilerinden değerli bilgiler elde etmelerini sağlayan güçlü bir araç ve teknoloji kombinasyon olmaktadır. Bu entegrasyon, kullanıcıların her iki platformun yeteneklerinden yararlanmasını sağlayarak verimli veri analizi, tahmine dayalı modelleme ve veriye dayalı karar verme süreçlerine olanak tanımaktadır.
10. Estard Data Miner: Estrad Data Miner, veri madenciliği amacıyla kullanılan bir yazılımdır. Bu yazılım, kuruluşların ve bireylerin verilerinden maksimum değeri elde etmelerine yardımcı olmak için özel olarak tasarlanmıştır. Tahmine dayalı modelleme, kümeleme, birliktelik kuralı madenciliği ve karar ağacı analizi gibi bir dizi veri madenciliği tekniği sunmaktadır.
11. DB miner: DB Miner, ilişkisel veritabanlarında veri keşfi ve madencilik görevleri için kullanılan bir yazılım aracıdır. DB Miner, sınıflandırma, kümeleme, birliktelik kuralı madenciliği ve dizi analizi dahil olmak üzere bir dizi veri madenciliği görevini desteklemektedir.
12. R Data Mining: Açık kaynaklı bir programlama dili ve ortamı olan R, güçlü veri madenciliği yetenekleri nedeniyle veri bilimcileri ve analistleri arasında büyük

bir popülerlik kazanmıştır. Kapsamlı kütüphaneleri ve araçları ile R, veri temizleme, dönüştürme, modelleme ve değerlendirme için verimli ve etkili bir ortam sağlamaktadır.

13. IBM Intelligent Miner: IBM Intelligent Miner, işletmelerin büyük hacimli verileri daha iyi analiz etmesine ve bu verilere dayanarak bilinçli kararlar almasına yardımcı olabilecek güçlü bir veri madenciliği araçlarıdır. IBM Intelligent Miner, veri tabanındaki veriler gibi yapılandırılmış verilerin yanı sıra metin dosyaları veya e-postalar gibi yapılandırılmamış verilerle de kullanılabilir.
14. KNIME: Knime, kullanıcıların keşifsel veri analizi, tahmine dayalı modelleme ve veri görselleştirme yapmalarına olanak sağlamak üzere tasarlanmıştır. Çeşitli veri formatlarını destekleyebilir ve veri tabanları, elektronik tablolar ve bulut hizmetleri dahil olmak üzere bir dizi veri kaynağıyla çalışabilmektedir.
15. Python: Python, veri madenciliği için kullanılacak bir dizi kütüphane ve araç sağlamaktadır. Bu kütüphaneler, kullanıcıların verilerden elde edilen içgörülerini iletmeye yardımcı olan çizelgeler, grafikler ve görselleştirmeler oluşturmalarına olanak tanımaktadır.

2.1. Veri Madenciliğinin Teknikleri

Veri madenciliği teknikleri, büyük ve karmaşık veri kümelerinden değerli belgeleri analiz etmek ve çıkarmak için güçlü araçlar sunmaktadır. Bu tekniklerin anlaşılması, veri bilimcilerin ve analistlerin kendi özel veri madenciliği görevleri için en uygun yöntemleri seçmelerine ve anlamlı ve eyleme dönüştürülebilir sonuçlar elde etmelerine yardımcı olmaktadır.

Veri madenciliği teknikleri, büyük ve karmaşık veri kümelerinden anlamlı örüntüler, bilgiler ve kazanımlar çıkarmak için kullanılan temel araçlardır. Bu teknikler, verilerdeki gizli ilişkileri ve eğilimleri ortaya çıkarmak için istatistiksel analiz, makine öğrenimi algoritmaları ve örüntü tanımadan yararlanmaktadır. Veri madenciliği bu teknikleri kullanarak analitik verileri görselleştirerek değişimleri, trendleri takip ederek verilerden anlam çıkartabilmeyi sağlamaktadır.

Veri madenciliği teknikleri arasında istatistikler, kümeleme, modelleme, karar ağaçları, yapay sinir ağları ve sınıflandırma teknikleri yer almaktadır.

2.1.1 İstatistikler

Veri madenciliğinde istatistik, içgörü elde etmek amacıyla verileri analiz etmek ve yorumlamak için matematiksel tekniklerin kullanılmasını içermektedir. Bu tekniklerin kullanılması istatistiğin genellikle büyük miktarlardaki veriyi analiz etmesini, örüntüleri ve ilişkileri belirlemesini, tahminlerde bulunmasını veya sınıflandırma yapmasını sağlamak için kullanılmaktadır. İstatistik sayesinde veri madenciliğinde bilinçli kararlar alınması sağlanmaktadır. Veri madenciliğinde kullanılan istatistikler:

1. Tanımlayıcı İstatistikler: Bir veri kümesinin temel özelliklerini özetlemek ve tanımlamak için kullanılmaktadır. Ortalama, medyan, mod, standart sapma ve yüzdelik dilimler gibi ölçütler verilerin merkezi eğilimini, dağılımını ve şeklini anlamaya yardımcı olmaktadır.
2. Çıkarımsal İstatistik: Bir veri setine dayanarak yapılan analizleri genellikle aynı özelliklere sahip veriler hakkında çıkarımlar veya tahminler yapmak için kullanılmaktadır. Regresyon analizi, hipotez testi ve güven aralıkları gibi yöntemlerle değişkenler arasındaki ilişkileri hakkında sonuçları çıkarmaya ve tahminlerde bulunmaya yardımcı olmaktadır.
3. Olasılık Dağılımları: Olasılık dağılımlarını anlamak, verilerdeki belirsizliği ve rastgeleliği modellemek için veri madenciliğinde temelde yer almaktadır. Kullanılan yaygın dağılımlar arasında normal, binom, Poisson ve üstel dağılımlar yer almaktadır.
4. Korelasyon ve Kovaryans: Değişkenler arasındaki ilişkiyi ölçen istatistiklerdir. Korelasyon, rassal iki değişken arasındaki doğrusal ilişkinin gücünü ve yönünü gösterirken kullanılmakta, kovaryans ise bu ilişkinin beraber değişimlerini incelemektedir.
5. Regresyon Analizi: Bağımlı bir değişken ya da bağımsız değişken arasındaki ilişkiyi modellemek için kullanılmaktadır.
6. Sınıflandırma ve Kümeleme Algoritmaları: Sınıflandırma veri setlerindeki her bir verinin hangi kategoriye ayrılacağını belirlemek için eğitilmektedir. Kümeleme ise denetimsiz veri setleri üzerinde çalışarak verileri benzerliklerine göre ayırmaktadır.
7. Model Değerlendirme: Veri madenciliği modellerinin ve algoritmalarının performansını değerlendirmek için doğruluk, kesinlik, geri çağırma, F1-skoru, ROC eğrileri ve AUC gibi istatistiksel ölçütler kullanılır.

Genel olarak istatistikler, veri madenciliğinde verilerin anlaşılması, analiz edilmesi ve yorumlanması için temel oluşturarak veri bilimcilerin değerli içgörüler elde etmesini ve bilinçli kararlar almasını sağlamaktadır.

2.1.2. Sınıflandırma

Sınıflandırma, verileri özelliklerine veya niteliklerine göre önceden tanımlanmış sınıflara veya kategorilere ayırmayı içeren denetimli bir öğrenme tekniğidir. Tahmine dayalı bir model oluşturmak için bilinen sınıf etiketlerine sahip geçmiş verileri kullanmaktadır. Sınıflandırma algoritmalarına örnek olarak karar ağaçları (Decision Tree), rastgele ormanlar (Random Forest), destek vektör makineleri (Support Vector Machine-SVM), k-en yakın komşu (K-Nearest Neighborhood-KNN), ve Naive Bayes verilebilmektedir. Sınıflandırma teknikleri spam filtreleme, duygu analizi, dolandırıcılık tespiti ve müşteri segmentasyonunda uygulama alanı bulmaktadır.

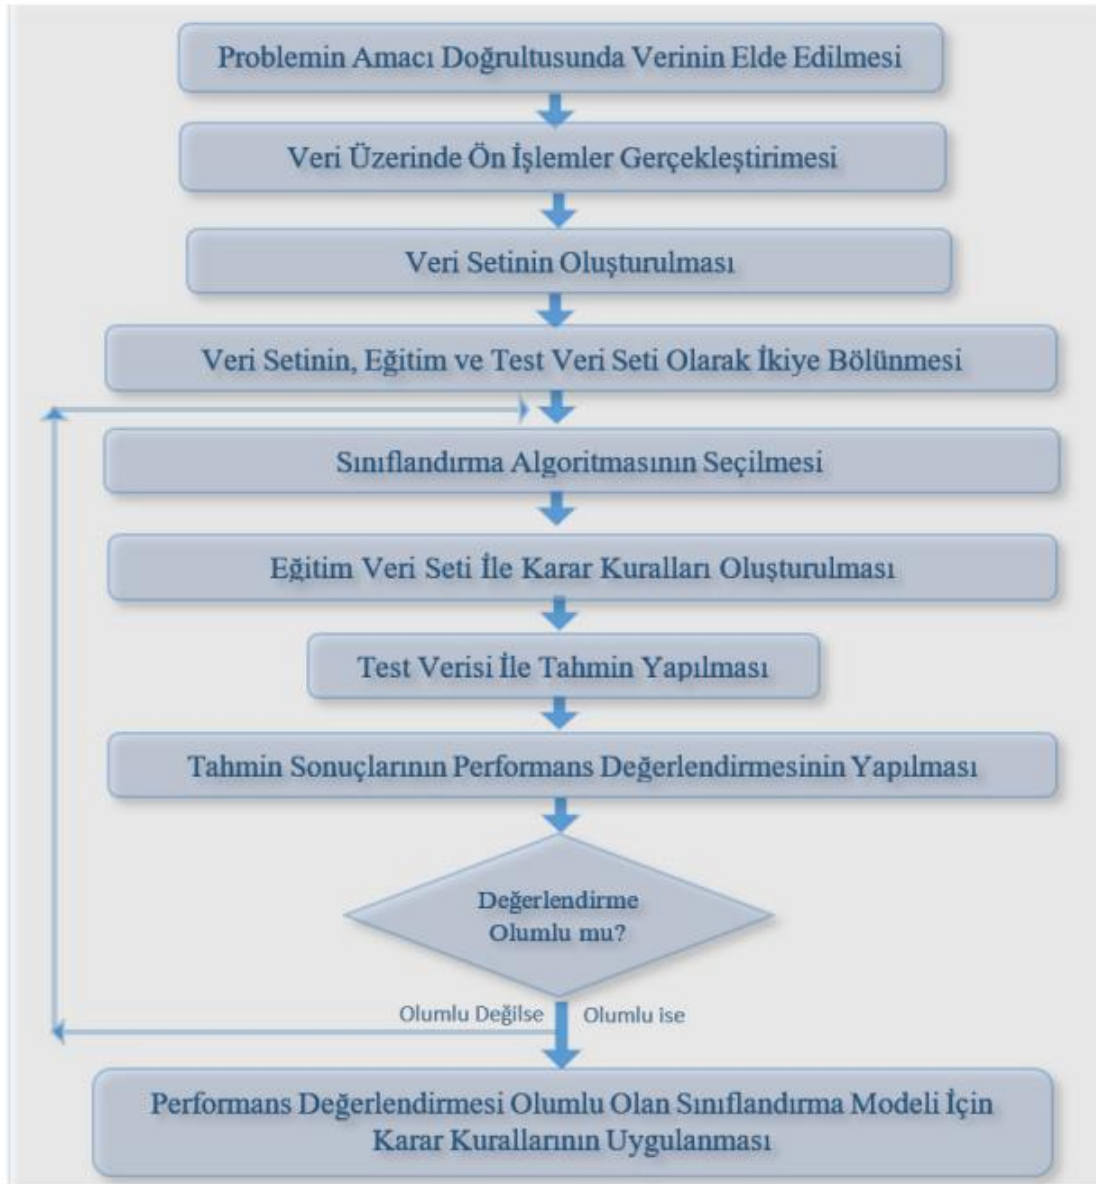
Sınıflandırma kavramı, bir veri kümesindeki (data set) tanımlı olan farklı sınıflar arasında veriyi dağıtmaktadır (Yıldız, Şeker, 2016). Sınıflandırma algoritmaları, verilen eğitim data setinden dağılım şeklini öğrenmektedirler ve daha sonra sınıfı belli olmayan test verileri ise doğru şekilde sınıflandırmaya çalışmaktadırlar (Yıldız, Şeker, 2016). Bu sayede verilerin sınıflandırılma yapılması daha verimli bir sonuçların alınmasına olanak sağlamaktadır.

Sınıflandırma işlemi, yeni verileri başarılı bir şekilde sınıflandırabilen iyi eğitilmiş bir sınıflandırıcı modeli gerektirir. Bu modelin amacı, yeni kayıtlar eklendiği zaman mümkün olduğunca doğru bir sınıfa atamasının gerçekleştirilmesini sağlamaktadır. Sınıflandırma modeli verilerin dağılımına göre bir model bulmaktadır. Böylelikle model bulunarak gelecekte ya da bilinmeyen değerlerin tahmin edilmesi için kullanılmaktadır.

Sınıflandırmadaki en önemli zorluklardan biri modelin sağlam ve doğru olmasını sağlamaktır. Bu, problemin hem istatistiksel hem de hesaplama yönlerinin dikkatli bir şekilde değerlendirilmesini gerektirmektedir. Ayrıca, modelin doğru sınıflandırmalar yapmasını sağlayacak doğru özellik (veya nitelik) kombinasyonunu seçmek de önemlidir.

Sınıflandırmanın temel bileşenlerini ve uygulamalarını anlamak, veri bilimcileri ve analistleri tahmine dayalı modelleme ve karar destek sistemleri için veri madenciliğinin gücünden yararlanma konusunda güçlendirmektedir. İşletmeler, sınıflandırma tekniklerini etkin bir şekilde kullanarak değerli bilgilerin kilidini açabilir, operasyonel verimliliği artırabilir ve veriye dayalı stratejiler geliştirebilmektedir.

Şekil-11: Sınıflandırma Süreci



Kaynak: Çınar, 2019: 96.

Veri madenciliğinde sınıflandırma yapılırken Şekil 11'deki süreçler izlenmektedir. Bu süreçlerle veriler sınıflandırma algoritmaları sayesinde sınıflandırma modeli elde etmektedirler. Böylelikle veri setindeki verilerin üzerinde sınıflandırma algoritmalarından biri uygulanması sonucunda model oluşturulur ve veri setiyle sınıf tahmini yapılarak, modelin tahmin sonucunda bir ölçüm değeri elde edilmektedir.

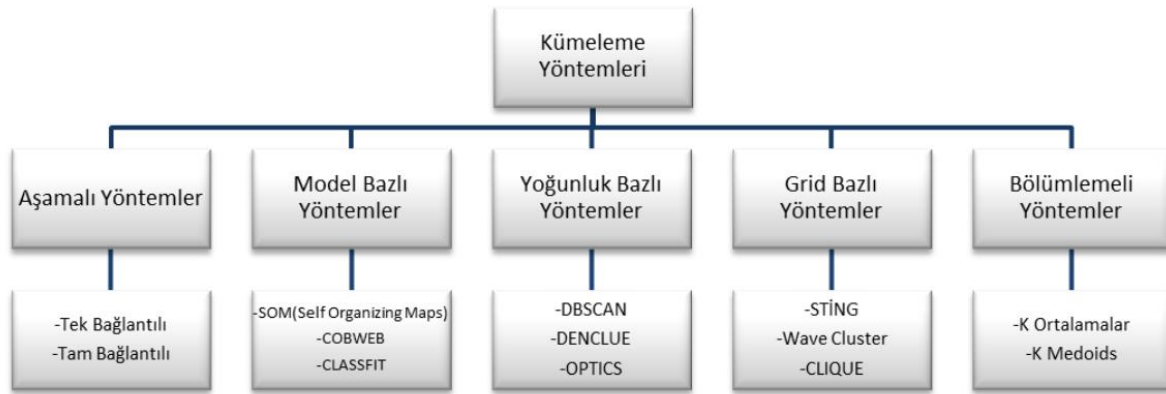
2.1.3. Kümeleme

Kümeleme, benzer veri noktalarını içsel desenlerine ve benzerliklerine göre bir araya getiren denetimsiz bir öğrenme tekniğidir. Sınıf etiketleri hakkında önceden bilgi sahibi

olmadan veri içindeki doğal gruplamaları belirlemeye yardımcı olmaktadır. Popüler kümeleme algoritmaları arasında k-ortalamalar, hiyerarşik kümeleme ve DBSCAN yer alır. Kümeleme, müşteri segmentasyonu, anomali tespiti, görüntü segmentasyonu ve belge kümelemede uygulama alanı bulur. Kümeleme teknikleri, keşifsel veri analizi, örüntü tanıma ve veri odaklı karar verme süreçlerinde önemli bir rol oynamaktadır.

Kümeleme, bir veri kümesini, aynı küme içindeki örneklerin farklı kümelerdeki örneklere kıyasla birbirine daha çok benzediği farklı gruplara veya kümelere bölme işlemidir. Amaç, küme içi benzerliği en üst düzeye çıkarmak ve kümeler arası benzerliği en aza indirmektir. Kümeleme, verilerin altında yatan yapıyı anlamaya, doğal gruplamaları tanımlamaya ve ilginç kalıpları veya aykırı değerleri keşfetmeye yardımcı olur.

Şekil-12: Kümeleme Yöntemleri



Kaynak: Sarıman, 2019: 194.

Kümeleme modellerindeki amaç küme üyeleri arasındaki benzerliğin olması, ancak nitelikleri birbirinden farklı birçok kümenin bulunması ve veri tabanında kayıtlı olan verilerin farklı kümelere bölünmesini sağlamaktadır (Arslan, 2008). Böylelikle kümelemenin başka bir hedefi ise benzer elemanların gruplandırılmasıyla veri setinin küçülmesini sağlamaktadır (Pang-Ning Tan vd., 2006).

Kümelemenin yapılması veri setindeki bireylerin ya da nesnelerin sınıflandırılmasını detaylı bir şekilde ortaya konulması için yapılmaktadır. Bu sayede veri setlerindeki ayırt edici özellikler ortaya konulmaktadır.

2.1.4. Modelleme

Modelleme teknikleri veri madenciliğinde kritik bir rol oynar ve kuruluşların doğru tahminler yapmak, gizli kalmış bilgileri ortaya çıkarmak ve değerli içgörüler elde etmek için

verilerinden yararlanmalarını sağlamaktadır. Bu teknikler, geçmiş verilere dayanarak bilinçli kararlar verebilen öngörücü modeller oluşturmak için matematiksel ve istatistiksel algoritmalar kullanmaktadır.

Veri madenciliği, kuruluşların verilerini daha iyi anlamalarına ve mevcut bilgilere dayanarak bilinçli kararlar almalarına yardımcı olabilecek bir dizi modelleme tekniğini içermektedir. Kuruluşların bilinçli kararlar almasına, operasyonları optimize etmesine ve günümüzün veri odaklı dünyasında rekabet avantajı elde etmesine olanak tanımaktadır.

Modelleme ile işletmelerde müşteri davranışının tahmin edilmesi, satış tahmininde bulunulması, risk değerlendirilmesi ve talep planlamasında kullanılmaktadır. Böylelikle müşterilerin bölümlendirilmesinde, pazarlama kampanyalarının kişiselleştirilmesine ve müşterinin elde tutulma stratejilerinin geliştirilmesine yardımcı olmaktadır. Müşterilerin bölümlendirilmesinde, kayıp tahmininde, çapraz satış ve tavsiye sistemlerinin geliştirilmesinde kullanılmaktadır.

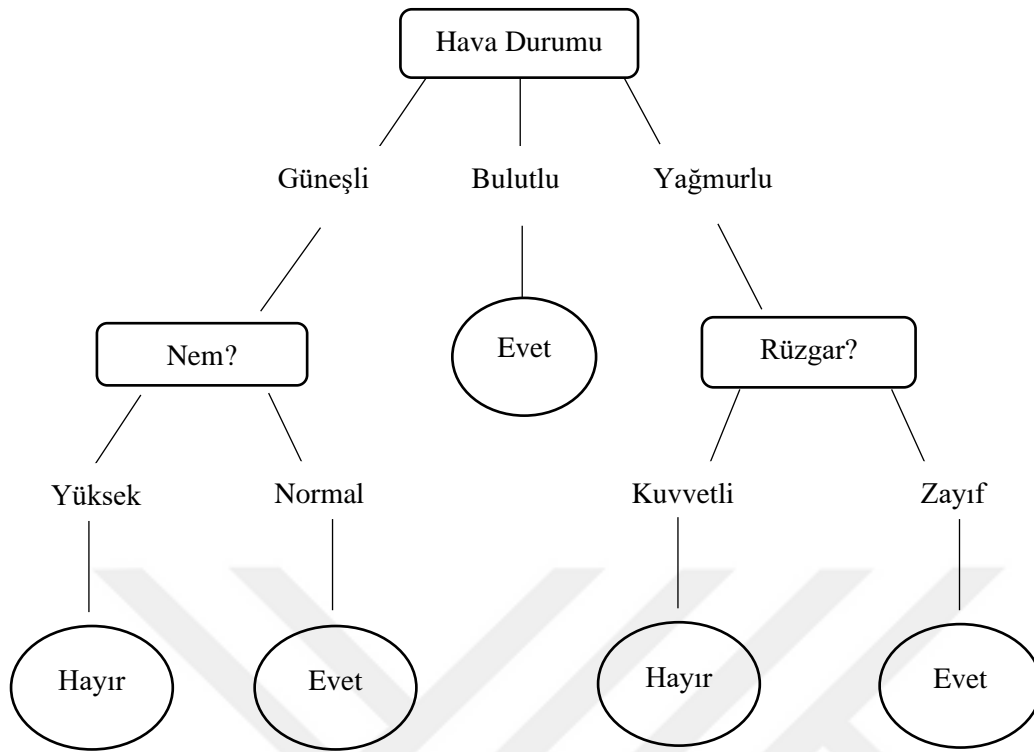
Modelleme tekniği ile tedarik zinciri operasyonlarını, envanter yönetimini, talep tahminini, lojistik planlamasını optimize etmektedir. Verimliliği artırmakta, maliyetleri düşürmekte ve tedarik zinciri yönetiminde karar verme sürecini geliştirmektedir.

2.1.5. Karar Ağaçları

Karar ağaçları veri madenciliğinde kullanılmakta olan güvenilir algoritmalardan bir tanesidir. Karar ağaçlarının veri tabanlarıyla birlikte bağlantılı olarak çalışması kolay uygulanabilir olması ve güvenli olmasını sağlamaktadır. Karar ağaçları geniş bir kullanım alanı ile öne çıkmaktadır.

Karar ağaçları, veri madenciliğinde karmaşık veri kümelerini anlamaya ve analiz etmeye yardımcı olan önemli araçlardandır. Karar ağacı, bir dizi kararın ve bunların olası sonuçlarının grafiksel bir gösterimidir. Kararları ve olası sonuçlarını bir dizi dalda haritalayan ağaç benzeri bir modeldir. Her dal bir kararı veya bir seçim noktasını temsil eder ve her dalın sonu bir sonucu temsil etmektedir.

Şekil-13: Örnek Karar Ağacı Yapısı



Kaynak: Dalkılıç, Dalkılıç, 2015: 799.

Yukarıdaki şekil, hava durumunun çeşitli özellikleri ele alınarak veriler üzerinden öğrenilmesi durumunda tahmini olarak elde edilecek sonuçlar ortaya çıkmaktadır. Bu sonuçlar sayesinde ağacın çeşitli girdilere göre dallanması görülmektedir. Yapraklarda ise elde edilmek istenen değerler gösterilmektedir.

Karar ağaçları, karar verme ve tahminde şeffaf ve yorumlanabilir bir yaklaşım sunan veri madenciliğinin değerli araçlarından biridir. Hem kategorik hem de sayısal verileri işleme yetenekleri, yorumlanabilirlikleri ve özellik önem analizleri onları müşteri segmentasyonu, kredi puanlaması, tıbbi teşhis ve dolandırıcılık tespiti gibi alanlarda yaygın olarak uygulanabilir kılmaktadır. Karar ağacı modellemesine yönelik yapım sürecini ve en iyi uygulamaları anlamak, veri madencilerinin ve analistlerin bu modellerin gücünden yararlanmalarını ve veri kümelerinden anlamlı içgörüler ortaya çıkarmalarını sağlamaktadır.


Karar ağaçları hem sınıflandırma hem de regresyon görevlerini yerine getirebilir ve bu da onları verilerden içgörü elde etmek için çok yönlü araçlar haline getirmektedir. Sınıflandırmada karar ağaçları, verileri özelliklerine göre kategorilere veya gruplara ayırmak için kullanılmaktadır. Regresyonda, karar ağaçları bir dizi tahmin edici değişkenden bir çıktı değişkeninin değerlerini tahmin etmek için kullanılmaktadır.

2.1.6. Yapay Sinir Ağları

Dijital teknolojiler, tedarik zinciri operasyonlarında devrim yaratarak verimliliğin artmasına ve karar alma süreçlerinin iyileşmesine yol açmıştır. Tedarik zinciri yönetimini dönüştüren kilit teknolojilerden biri de yapay sinir ağlarıdır (Helo & Hao, 2021). İnsan beyninin sinir ağından esinlenen bu ağlar, tedarik zinciri yönetiminin çeşitli yönlerini optimize etmede büyük potansiyel göstermiştir.

Yapay sinir ağları, talep tahmini, envanter optimizasyonu ve rota optimizasyonu gibi çok çeşitli tedarik zinciri yönetimi görevlerine uygulanmıştır. YSA'ların büyük veri kümelerindeki karmaşık örüntüleri ve doğrusal olmayan ilişkileri analiz etme yeteneği, onları tedarik zinciri operasyonlarında karar verme sürecini geliştirmek için değerli bir araç haline getirmektedir (Teuteberg, 2008) (Min, 2009).

Şekil-14: Yapay Sinir Ağı



Kaynak: Öztürk, Şahin, 2018: 31.

Talep tahmininde, YSA'lar geleneksel tahmin yöntemlerinin gözden kaçırabileceği birden fazla değişkeni yakalayıp analiz ederek daha doğru tahminler yapılmasını sağlayabilir. Benzer şekilde, envanter optimizasyonunda, YSA'lar talep modellerinin belirlenmesine ve stok seviyelerinin buna göre ayarlanmasına yardımcı olabilir, sonuçta hizmet seviyelerini korurken envanter taşıma maliyetlerini azaltabilir (Paul ve Azeem, 2011) (Guo vd., 2014) (Min, 2009)

Ayrıca, YSA'lar mesafe, trafik koşulları ve teslimat süresi gereksinimleri gibi faktörleri dikkate alarak malların taşınması için en verimli rotaları belirlemek üzere rota optimizasyonunda kullanılabilir (Zou & Zhang, 2018).

Ayrıca, rota optimizasyonunda, YSA'lar en verimli teslimat rotalarını önermek için trafik modelleri, teslimat kısıtlamaları ve gerçek zamanlı veriler gibi çeşitli faktörleri göz önünde bulundurabilir, böylece nakliye maliyetlerini ve teslimat sürelerini en aza indirebilir. (Soori, vd., 2023 ve Satyananda & Abdullah, 2021)

Yapay sinir ağlarının tedarik zinciri yönetimindeki potansiyeli çok büyüktür ve teknoloji ilerlemeye devam ettikçe uygulamalarının daha da artması beklenmektedir. Bu teknolojileri benimseyen ve bunlardan yararlanan sektörlerin günümüzün hızlı ve dinamik tedarik zinciri ortamında rekabet avantajı elde etmesi muhtemeldir.

2.2. Tedarik Zincirinde Veri Madenciliği

Tedarik zincirinde veri madenciliğinin uygulanması, rotalama ve çizelgelemeyi optimize etmek için makine öğrenimi algoritmalarının kullanılmasını da içerebilmektedir. Şirketler, geçmiş nakliye verilerinden ve gerçek zamanlı bilgilerden yararlanarak lojistik ağlarının verimliliğini artırabilir, nakliye maliyetlerini düşürebilir ve teslimat hızını artırabilmektedirler (Congna vd., 2009 ve Bu, 2021). Bir diğer önemli strateji de tedarik zincirinde sahtekârlığı tespit etmek ve önlemek için veri madenciliği tekniklerini uygulamak ve böylece potansiyel mali kayıplara ve itibar zedelenmesine karşı koruma sağlamaktır. Ayrıca, tedarikçi performansını analiz etmek için veri madenciliğinden yararlanmak, daha iyi sözleşmelerin müzakere edilmesine ve genel tedarik zinciri esnekliğinin artırılmasına yardımcı olunmasını sağlamaktır (Govindan vd., 2018). Tedarik zincirinde talep tahmini için veri madenciliği kullanmak, şirketlerin üretim programlarını ve envanter seviyelerini daha doğru bir şekilde planlamalarını sağlayarak stoksuzluk ve aşırı stok durumlarını azaltabilmektedirler (Seyedan & Mafakheri, 2020). Şirketler bu stratejileri uygulayarak rekabet avantajı elde edebilir ve tedarik zinciri operasyonlarında daha fazla verimlilik ve etkinlik sağlayabilmektedir.

Veri madenciliği, kuruluşların tedarik zinciri süreci boyunca üretilen büyük miktarda veriyi analiz etmesine ve anlamasına yardımcı olarak tedarik zinciri yönetiminde çok önemli bir rol oynamaktadır. Şirketler, gelişmiş veri analitiği ve makine öğrenimi algoritmalarından yararlanarak, tedarik zinciri operasyonlarını optimize etmek için büyük miktarda veriden değerli içgörüler elde edebilmektedir. Şirketler veri madenciliği tekniklerinden yararlanarak

tedarikçi performansı, talep tahmini, envanter yönetimi ve müşteri davranışına ilişkin değerli içgörülerini ortaya çıkarabilmektedir.

Veri madenciliğini tedarik zincirine uygulamanın en önemli faydalarından biri, karar verme ve operasyonel verimliliği artırabilecek kalıpları ve eğilimleri belirleme yeteneğinin oluşmasını sağlamaktır. Bu sayede talebi doğru bir şekilde tahmin edebilmektedir. Geçmiş satış verilerini, pazar trendlerini ve diğer ilgili faktörleri analiz ederek işletmeler gelecekteki talebi daha hassas bir şekilde tahmin edilebilmektedir (Huang vd., 2022). Örneğin, tahmine dayalı analitik, talebi daha doğru tahmin etmek için kullanılabilir, bu da envanter seviyelerinin optimize edilmesine ve taşıma maliyetlerinin azaltılmasına yol açmaktadır. Ayrıca, veri madenciliği potansiyel tedarik zinciri risklerinin ve fırsatlarının belirlenmesine yardımcı olarak proaktif ve stratejik karar alma süreçlerindeki maliyetlerin düşmesine ve müşteri memnuniyetinin artmasına yol açmaktadır (Fink vd., 2012).

Veri madenciliği tedarik zincirinde risk yönetiminde de önemli bir rol oynamaktadır. İşletmeler, piyasa hareketliliği, jeopolitik olaylar ve tedarikçi güvenilirliği gibi çeşitli risk faktörlerini analiz ederek, öngörülemez aksaklıklar karşısında dayanıklılığı ve uyarlanabilirliği artırmak için risk azaltma stratejileri geliştirebilmektedir.

Veri madenciliği, iyileştirme alanlarını ve maliyet tasarrufu fırsatlarını belirleyerek tedarikçi ilişkileri yönetimini geliştirmek için uygulanabilmektedir. Geçmiş verileri ve performans ölçümlerini analiz ederek kuruluşlar tedarikçi yeteneklerini, işbirliğini ve verimlilik kazanımları için potansiyel alanları daha iyi anlayabilmektedir.

Veri madenciliğinin tedarik zincirine entegrasyonu, görünürlüğü artırmak, operasyonları optimize etmek ve tüm tedarik zinciri ağı boyunca işbirliğini teşvik etmek için gereklidir. Kuruluşlar dijital dönüşümü benimsemeye devam ettikçe, veri madenciliği tekniklerinden yararlanma, eyleme geçirilebilir istihbarat elde etme yeteneğinin oluşması ve tedarik zincirinin geleceğinin şekillendirilmesinin sağlanması ile günümüzün hızla gelişen iş ortamında rekabetçi ve çevik kalmak için çok önemli bir konumda yer almaktadır.

ÜÇÜNCÜ BÖLÜM

WEKA PROGRAMI

Makine öğreniminde ve veri madenciliğinde kullanılmak üzere Weka (Waikato Environment for Knowledge Analyses) programı, Waikato Üniversitesi tarafından 1996'da ilk versiyonu yayınlanmıştır (Tapkan vd., 2011). Witten vd. (2011) göre makine öğrenimi algoritmalarını entegre eden, kullanışlı bir grafikli arayüze sahip, açık kaynaklı bir veri analizi uygulamasıdır. Weka birçok veri kümesinin ön işlemlerini, sınıflandırılmasını, regresyonunu, kümelemesini, ilişkilendirilme kurallarını ve görselleştirilme araçlarını bulundurmaktadır (Tapkan vd., 2011). Doğrudan veri kümesiyle veya Java kodu ile çağırılan algoritmalar kullanılmaktadır (İşler & Narin, 2012). Weka akademik araştırmalarda, eğitimlerde ve endüstriyel alanlarda kullanılırken, verileri analiz etmekte ve tahmin edici modeller için gelişmiş olan algoritmaları ve araçları görselleştirerek birleştirmektedir (Tapkan vd., 2011).

Weka ile veri madenciliği için 3 temel işlem yapılabilir:

1. Sınıflandırma (*Classification*)
2. Bölütleme (*Clustering*)
3. İlişkilendirme (*Association*)

Yukarıdaki işlemlere ek olarak veri setleri üzerinde ön ve son işlemleri yapılabilir bunlar:

1. Veri Ön İşleme (*Data Pre-Processing*)
2. Görselleştirme (*Visualization*)

Weka üzerinde veri setlerini kullanarak analiz ve yorumlama yapabilmek için yukarıdaki işlemler uygulanarak analiz ve yorumlama yapılabilmektedir.

Weka'da veri setlerinin daha iyi analiz edilebilmesi için özellik seçimi yapılmaktadır. Bu seçimi veri tabanı ya da veri setlerinin çok sayıda öznitelik içerdiği zaman aranmakta olan analizde gereksiz birkaç öznitelik olacaktır. Aslında tüm öznitelikler sınıflandırılmak için her zaman sınıflandırılan özelliklerle doğrudan ilgili olmamaktadır. Veri setindeki alakasız öznitelikler bazı algoritmalarda performans düşüklüğüne sebep olmaktadır. Bu sebeple özellik seçiminde veri kümesinin en çok ilişkili yönlerinin seçilmesi sağlanmaktadır. Weka özellik seçiminde otomatik araçlar sağlamaktadır.

Weka programı kendisiyle uyumlu çalışan özgün bir uzantı olan .arff ile çalışmaktadır (Elabıad, 2013). ASCII tabanlı olan uzantı .arff ve csv uzantısının dönüştürülerek kullanılmaktadır (Elabıad, 2013).

Weka'nın ilk açılışında kullanıcılara gösterilen ana ara yüz ekranı gelmektedir. Bu ara yüzde bulunan "Program", "Visualization", "Tools" ve "Help" üst kısımda olan ve "Applications" kısmında bulunan "Explorer", "Experimenter", "Knowledge Flow", "Workbench" ve "Simple CLI" menüleri yer almaktadır (İşler & Narin, 2012).

Şekil-15: WEKA Önyüz



Şekil 15'te gösterilen bu ana yüz penceresinde bulunan sekmelerin ne iş yaptıklarını kısaca özetleyebiliriz.

"Explorer" modülü verileri kümeler, sınıflandırır, ilişki analizi yapar, özellik seçer ve görselleştirme yapma olanağını kullanıcıya sağlayarak araştırmalara yönelik ara yüzüdür (Elabıad, 2013).

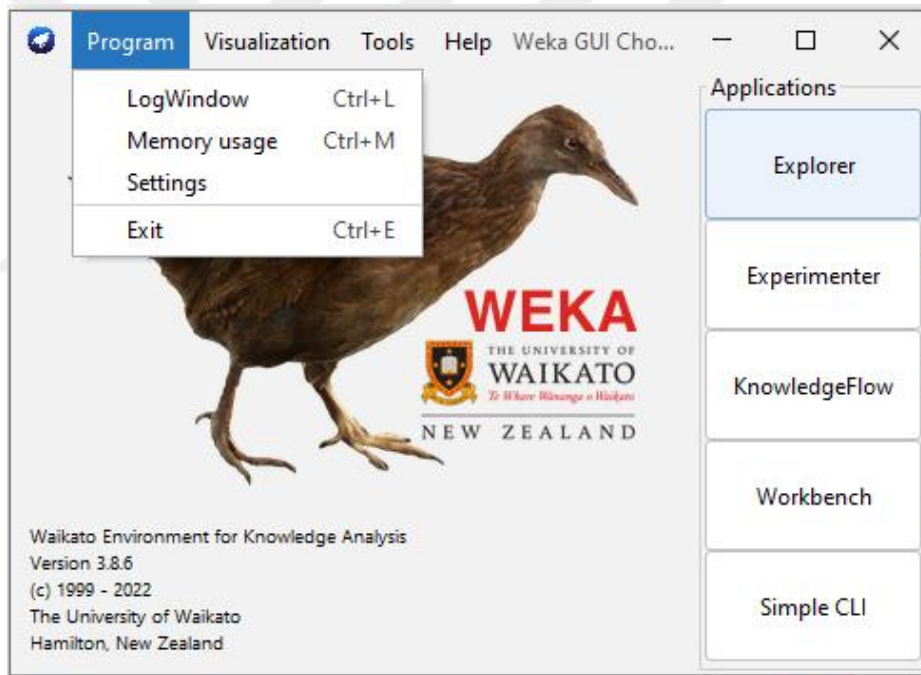
Bir veya daha fazla olan veri kümeleri üzerinde daha fazla veya bir algoritma uygulanması ve gözlemlenmesi için kullanıcıya seçenek sunan "Experimenter" ara yüzü bulunmaktadır (İşler & Narin, 2012).

“Knowledge Flow” “Explorer”da çalışan veya çalışmış olan veri kümelerini görsel yolla sürükle-bırak mantığıyla planlanabilmesi için geliştirilmiş seçenektir (İşler & Narin, 2012). Weka içerisinde bulunmakta olan kütüphanelere erişmek için Knowledge Flow modülündeki görsel ortamlardan yardım alınmaktadır (Elabiad, 2013).

Workbench ara yüzü; Weka'nın içerisinde bulunan işlevleri ve görselleri elde edebileceğiniz ve değişkenleri düzenleyebileceğiniz modüldür (Uslu, 2019). Bu modülde ileri seviye değişimler yapılabilir (Uslu, 2019).

“Simple CLI” “Basit Komut Satırı” ara yüzü ile temel düzeyde komutları çalıştırabileceğiniz bir kısımdır (Elabiad, 2013). Veri kümeleri ile olan çalışmalarını komutlarla yapmak için olanak sağlamaktadır (İşler & Narin, 2012).

Şekil-16: WEKA Program Menüsü

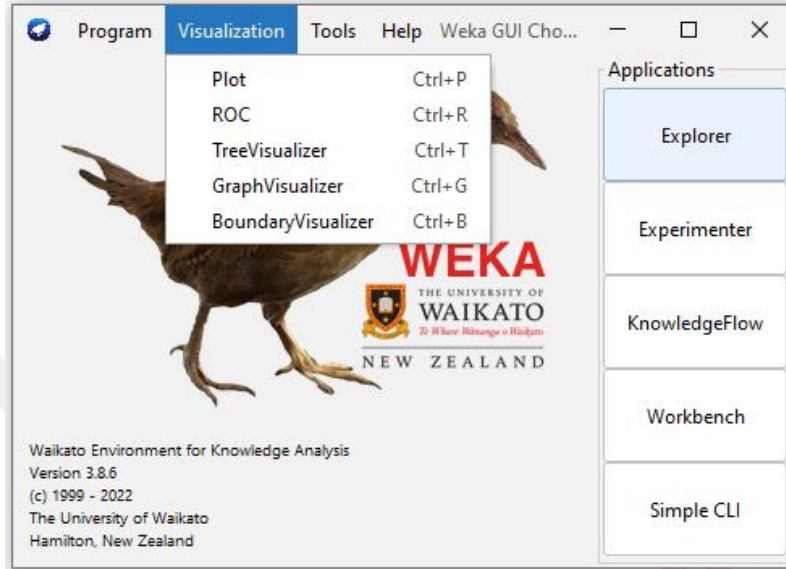


Bu pencerede açılan menülerin ne iş yaptıklarını kısaca açıklayabiliriz.

- LogWindow: Stdout veya stderr'ye yazdırılan her şeyi yakalayan bir günlük penceresi açmaktadır. WEKA'nın normalde bir terminalden başlatılmadığı Windows gibi ortamlar için kullanışlıdır. Weka programının hata ayıklama ve neler yaptığını izlemek için kullanılmaktadır
- Memory Usage: Ram kullanımını takip eder. Weka'nın veri işlenirken ve model oluştururken ne kadar bellek kullandığını izlemek için kullanılmaktadır.

- Settings: Arayüzün görünümünü ayarlarını ve soket iletişimi için zaman aşımı ayarlarını içermektedir. Weka'nın ağ parametrelerini ayarlamak için bu seçenekler kullanılmaktadır.
- Exit: Weka programının da çalışmanın sonlandırılması için kullanılmaktadır.

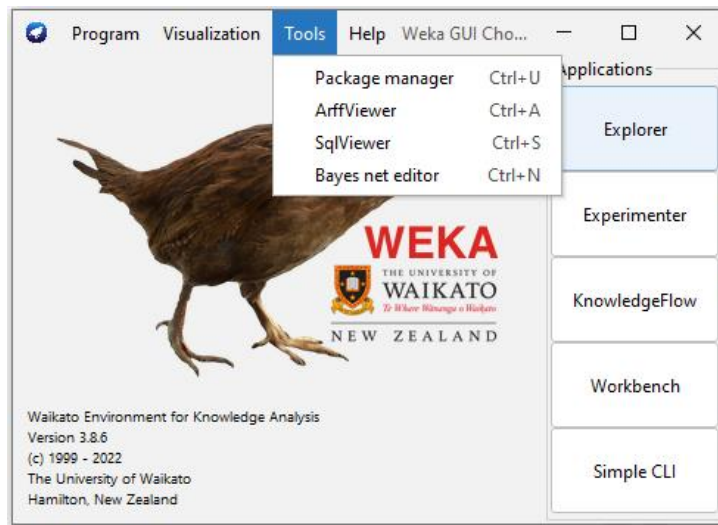
Şekil-17: WEKA Visualization Menüsü



Bu Şekil 17'deki açılır menü içerisinde bulunan işlevlerin ne iş yaptıklarını kısaca açıklayabiliriz.

- Plot: Veri kümesinin 2B çizimini çizmek kullanılmaktadır. Veri bulunan iki farklı veri noktalarının iki boyutlu düzlemde nasıl dağıldığını görselleştirilmesini sağlamaktadır.
- ROC: Weka daha önceden kaydedilmiş olan ROC eğrilerini görüntülemektedir.
- TreeVisualizer: Yönlendirilmiş grafikleri görselleştirmek, örneğin bir karar ağacını görüntülemektedir.
- GraphVisualizer: Veri setlerindeki düğümleri ve kenarları arasındaki ilişkileri ve bağımlılıkların anlamlandırılmasında kullanılmaktadır. XML BIF veya DOT biçimindeki grafikleri görselleştirmektedir.
- BoundaryVisualizer: Sınıflandırıcı karar sınırlarının iki boyutta görüntülenmesini sağlamaktadır. Veri setinin karmaşıklığı ve performansının değerlendirilmesi için kullanılabilir.

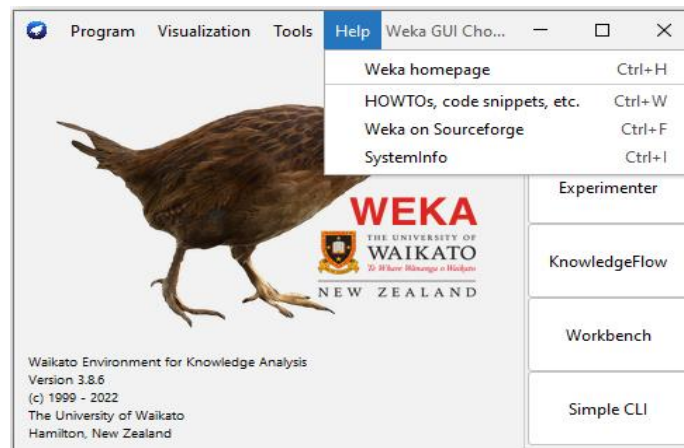
Şekil-18: WEKA Tools Menüsü



Bu penceredeki menüde bulunan işlemlerin ne iş yaptıklarını kısaca özetleyebiliriz.

- Package Manager: Weka' nın varsayılan özelliklerine ek yeni işlevsellikler yüklemek için kullanılmaktadır. Bu özellikler veri işleme araçları, görselleştirme ve yeni algoritmalar olabilmektedir.
- ArffViewer: ARFF dosyalarını elektronik tablo biçiminde görselleştirerek, veri setinin incelenmesine ve düzenlenmesine kolaylık sağlamaktadır.
- SqlViewer: JDBC (Java Database Connectivity) aracılığıyla veri tabanlarına bağlanmakta ve sorgulamalar çalıştırmak için bir SQL çalışma sayfası sunmaktadır.
- Bayes net editor: Bayes ağlarını düzenlemek, görselleştirmek ve öğrenmek için kullanılmaktadır. Bayes ağlarının oluşturulması, düzenlenmesi ve bu ağlar üzerinde çeşitli öğrenme algoritmaları için uygulama saptamaktadır.

Şekil-19: WEKA Help Menüsü



Bu pencerede bulunan açılır menüdeki işlemlerin ne iş yaptıklarını kısaca açıklayabiliriz.

- Weka Homepage: Weka' nın ana sayfasını web sayfasında tarayıcıda açmaktadır. Weka'nın, yazılımı, indirme bağlantıları, dokümantasyonları ve diğer kaynaklar hakkında bilgiler vermektedir.
- HOWTOs, code snippets, etc.: Weka'nın geliştirilmesi ve kullanımı hakkında birçok örnek ve HOWTOs (Nasıl Yapılır) belgelerinin ve kod parçacıklarının içerdiği WekaWiki sayfasını açmaktadır.
- Weka on Sourceforge: Weka' nın Sourceforge.net'teki proje ana sayfasını tarayıcıda açmaktadır. Weka'nın açık kaynak projelerini barındıran bir platformdur ve kaynak kodlarını, sürüm bilgilerini, kullanıcı yorumlarını ve projeye katkıda bulunulması gibi seçenekler bulunmaktadır.
- SystemInfo: Java / Weka ortamı ile ilgili bazı dahili bilgileri listelemektedir. Sorunların giderilmesi ve performans analizlerinin yapılması için yararlanılmaktadır.

Weka veri setleri üzerinde kendi içinde bulunan mevcut yöntemlerin kullanılmasını sağlayarak daha hızlı bir şekilde sonuç alınmasını ve detaylı analizler yapılmasına imkan tanımaktadır. Böylelikle weka sayesinde verilerin sınıflandırılması, kümelmesi ve ilişki analizi yapılmasını sağlamaktadır.

Weka ile veri setinin girişini hazırlamak, girdi verileri ve öğrenmenin sonuçlarının görselleştirilmesini ve bunlara ek olarak istatistiksel olarak değerlendirilmesini sağlamaktadır. Bu sayede birçok öğrenme algoritmasıyla analizler yapılmasına olanak tanımaktadır. Weka programı kullanıcılarına farklı yöntemlerle karşılaştırma yapmasına ve mevcut olan problemin en uygun olan öğrenme yeteneği seçeneği için arayüzler sunmaktadır.

Weka veri setleri için çok çeşitli görselleştirme araçları sunmaktadır. Weka'da veriler girdiler için tek bir dosyadan ya da tablodan okumaktadır. Weka kullanmak için veri setine uygun öğrenme yöntemlerinden birinin uygulanması ve çıktısının alınarak hakkında bilgi elde edilmesini ve çıktıların analiz edilmesini sağlamaktadır. Farklı bir yol olarak daha önce toplanmış veya yeni üretilmiş veriler üzerinden sonuçlar elde etmektir. Başka bir yol olarak ise veri seti üzerinde öğrenme yöntemlerini deneyerek ve bunlar arasında performansları karşılaştırma yapmaktır. Weka'nın içinde bulunan tüm öğrenme algoritmaları değiştirilebilir parametrelere sahiptir.

LİTERATÜR TARAMASI

Bu çalışmadaki kullanılan yöntemlerin adımlarının belirlenmesi ve ön bilgi sahibi olunması için benzer konularda daha önceden hazırlanmış olan tezlerden, makalelerden ve kitaplardan faydalanılmıştır. Bu kapsama dair yararlanılan kaynaklar hakkında aşağıda kısaca bilgi verilmiştir.

Yap Bee Wah, Ne de Huwaina İsmail ve Simon Fong taraflarından yapılan çalışmada araba rezervasyonu yapıldıktan sonra satın alma niyetinin tahmin edilmesi için tahmin modellerinin oluşturulması için veri madenciliği yöntemi kullanılmıştır. Müşterinin satın alma niyeti için üç tane veri madenciliği yöntemi: Logistic Regression (LR), Decision Tree (DT) ve Neural Network (NN) kullanılmıştır. Bu çalışma için 1935 tane veri setinden oluşmaktadır. Verilerin (%70) eğitim, (%30) test olarak ayrılmıştır. Bu üç tahmin modelinin performans karşılaştırmaları, doğruluk oranına, duyarlılığa ve özgüllüğe dayanılmıştır. Sonuç olarak üç modelin doğruluk oranları birbirlerine oldukça benzer olduğu (LR= %91,79, CART= %91,17, NN= %91,17) gösterirken, LR ise en yüksek duyarlılığa sahip olduğunu (LR= %87,77, CART= %85,47, NN= %85,89) göstermektedir (Wah, vd., 2011).

Dedy Suryadi, Alfian Tan ve Donny Boy taraflarından yapılan çalışmada bir şirkette ikinci el araç alımında karar verme sürecini incelemektedir. Bu çalışma alternatif olarak, şirket tarafından toplanan verileri kullanarak, karar verme sürecini iyileştirmek için bir veri madenciliği yaklaşımını kullanmıştır. Model olarak destek vektör makinesi (Support vector machine- SVM) başarılı bir şekilde satılıp satılmayacağını tahmin etmede %69,44'lük bir doğruluk sağlamıştır (Suryadi, vd., 2021).

Hamid Ahaggach, Lylia Abrouk, Sebti Fougou ve Eric Lebon taraflarından yapılan çalışmada otomotiv alanında otomobil satıcıları ve otomobil satışlarında tedarik zinciri için pazarlama stratejilerini geliştirilmesi amaçlanmıştır. Yeni arabaların maliyeti ve araba değerinin değer kaybetme riskinin yüksek olması nedeniyle, araba satıcılarının hangi tür arabaların diğerlerinden daha hızlı satılabileceğini bilmeleri gerekli hale gelmektedir, bu da satıcıların pazarlama stratejilerini uyarlamalarına ve müşterilerinin ihtiyaçlarını karşılamalarına olanak sağlayacaktır. Bu sorunu ele almak ve bu şirketlere karar verme süreçlerinde yardımcı olacak modeller oluşturmak için veri analizi ve makine öğrenimi kullanılmıştır. Araştırmalarında, çok üreticili otomobillerin iki büyük bayisinden alınan satış verileri kullanılmıştır. Veri kümesi, 8 yıllık bir süre boyunca yaklaşık 73200 otomobilin satış geçmişini

çermektedir. Decision trees (DT), Random forests (RF), Support vector machine (SVM) ve K-Nearest Neighbors (KNN) sınıflandırma algoritmaları kullanılmıştır. Bu dört modelin doğruluk oranları (KNN=%97,1, SVM=%95,1, DT=%99, RF=%99) olarak bulunmuştur. Farklı makine öğrenimi algoritmalarını karşılaştırarak ve otomobillerin farklı tahmini satış süresi aralıklarında sınıflandırarak gerekli incelemeler yapılmıştır (Ahaggach, vd., 2023).

Kyoung Jong Park tarafından yapılan çalışma, üreticiler, dağıtımıcılar, toptancılar ve perakendecilerden oluşan tedarik zinciri modelinin sürdürülebilirliğini güvence altına almak için tedarik zincirinde üretilen verileri bir makine öğrenme algoritması kullanarak analiz ederek tedarik zincirinin iniş çıkışları incelenmiştir. Bu çalışma, işletmelerin tedarik zinciri için kullandıkları sistemlerden veriler almakta ve bilinmeyen kaynaklardan yeni veriler ortaya çıktığında verilerin hangi işletmeye ait olduğunu bulmak için makine öğrenimi algoritmaları kullanılmaktadır. Kullanılan makine öğrenimi algoritmaları lojistik regresyon, rastgele orman, naive Bayes, karar ağacı, destek vektör makinesi, k-en yakın komşu ve çok katmanlı perceptron'dur. Makine öğrenimi yöntemlerinin performansını değerlendirmek için kullanılan ölçütler doğruluk, karışıklık matrisi, kesinlik, geri çağırma ve F1-skorudur. Bu ölçütler dikkate alınarak algoritmaların doğruluk oranları (LR=%100, NB=%83,9, DT= %83,9, RF= %94,8, DVM= %85,5, KNN= %89,2, MLP= %100) olarak bulunmuştur. Algoritmaların veri seti üzerindeki başarı oranları hesaplanmış ve çıkan sonuçlar karşılaştırılarak incelemeler yapılmıştır (Park, 2021).

Anamika Das Mou, Protap Kumar Saha, Sumiya Akter Nisher ve Anirban Saha taraflarından yapılan çalışmada, otomotiv endüstrisi, ülke ekonomisi için önde gelen endüstrilerden biri olması nedeniyle gün geçtikçe daha popüler hale gelmiştir. Bu nedenle müşteri doğru aracı satın almak istediğinde incelemeye ihtiyaç duymaktadır. Bir arabayı satın almadan önce yedek parça, silindir hacmi, far ve özellikle fiyat gibi birçok koşul ve faktör bulunmaktadır. Bu nedenle, müşterinin tüm kriterlerini karşılayabilecek doğru satın alma seçimini yapması önemli bir hale gelmiştir. Amaç, müşterinin araba satın alıp almayacağı konusunda doğru kararı vermesine yardımcı olmaktır. Bu nedenle, araç satın alma sisteminde müşterinin karar vermesi için bir yöntem oluşturulmak istenmiştir. Bu yöntem sınıflandırma algoritmaları ile yapılmıştır. Bu algoritmaların sonuçları Random Forest %60, K-Nearest Neighbors (KNN) %73, Naive Bayes %41 ve Support vector machine (SVM) %86,7 tahminde bulunmuştur. En iyi sonucu Support vector machine (SVM) %86,7 olarak tahmin vermiştir. Bu çalışmada, tüm algoritmalar için hassasiyet, geri çağırma ve F1 puanı kullanarak karşılaştırmalı sonuçları ortaya konulmuştur (Mou, vd., 2021).

Samdeep Kumar Panda tarafından yapılan çalışma, modern dünyada insanlar kolay yaşam için ulaşım alanında araba icat etmişlerdir. Bu arabaların her biri farklı özelliklere sahip olmaktadır ve insanlar bu özelliklere dayanarak arabayı satın almak istemektedirler. Bu araba satın alma yönündeki hareketlerini analiz etmektedirler. Bu nedenle, bu çalışmada bir müşterinin belirli özelliklere sahip araba satın alıp almayacağını sınıflandıran bir sınıflandırma modeli oluşturmaktadır. Bu araştırmanın analizinde dört makine öğrenme modelinden yararlanılmıştır. Bu sınıflandırma modelleri Gaussian Naïve Bayes, Decision Tree, K-Nearest Neighbors ve Neural Networks kullanılmıştır. Bu modeller arasındaki sonuçları karşılaştırmak ve gerçek zamanlı tahminde kullanılacak en iyi modele karar vermek kullanılmıştır. Müşterinin hangi özelliklere sahip arabayı satın almayacağını tahmin etmek için en iyi doğruluk oranını Decision Tree sınıflandırıcısı tarafından verilen %97,4 elde edilmiştir. Ayrıca Neural Networks sınıflandırıcısı da yaklaşık aynı doğruluğu vermiştir. Böylelikle, bu makine öğrenimi modeli işletme tarafından belirli bir arabanın diğer müşteriler tarafından satın alınıp alınmadığını bilmek için kullanılmıştır (Panda, 2022).

Michael Nico Hutasoit, Riska Yanu Farifah ve Rachmadita Andreswari taraflarından yapılan çalışmada Endonezya'da otomobil satışları 2014-2018 yıllarında 4157580 adet gibi oldukça yüksek bir rakam elde edilmiştir. En yüksek satışlar popüler araba türleri olan Sedan, SUV, 7 Kişilik SUV ve Şehir arabası türleri de dahil olmak üzere birçok araba türü yer almıştır. Rekabet eden fiyatlara sahip olan birçok otomobil markaları, tüketicilerin ihtiyaçlarına göre satın almak için doğru arabayı seçmeleri zorlaştırmıştır. Bu durum, k-means kümeleme algoritması kullanılarak otomobil satışlarına veri madenciliği uygulanarak çözülebilir olmasını sağlamıştır. Amaç, her bir özelliğe sahip otomobilin özelliklerini bilmektir. Beş niteliğe dayalı küme oluşumu için k-means algoritması kullanılmıştır. Böylelikle K-Means algoritması, diğer kümeleme algoritmalarından daha yüksek doğruluk oranına sahip olduğu için seçilmiştir. K-Means algoritmasının %56 doğruluk oranı vermiştir. Böylelikle k-means kümeleme algoritması uygulanarak doğru araba seçiminin belirlenmesi ile bir çözüm ortaya konulmuştur (Hutasoit, vd., 2023).

DÖRDÜNCÜ BÖLÜM

ARAŞTIRMANIN METODOLOJİSİ

4.1. Araştırmanın Konusu

Tedarik zincirinde bilişim teknolojilerinin kullanılması ile pek çok veri depolanmaktadır. Bu verilerin işlenmesi işletmelerin daha hızlı ve daha verimli karar verebilmesi için önemli bir yere sahiptir. İşletmeler verilerini kullanılabilir, yorumlanabilir ve keşif yapılabilir hale getirebilmesini sağlamak için veri madenciliği yöntemlerini kullanmaktadır. Büyük veriler arasından bilgiye ulaşma işini veri madenciliği yapmaktadır (Yıldız ve Şeker, 2016, s. 10). Veri madenciliği bilginin keşfedilmesi olarak da bilinmektedir (Bozkurt Uzan ve Özüçalışyan, 2020, s. 3469). Böylelikle tedarik zincirinde gelecek ay veya yılda ne kadar kar elde edebileceğini ve müşteri memnuniyeti hakkındaki verilere kolaylıkla ulaşarak tahminde bulunulmasını sağlamaktadır. İşletmeler bu verilerden yola çıkarak müşteri kitlelerini oluşturabileceklerdir. Bu sayede müşterinin istek ve ihtiyaçlarına veriler sayesinde hızlı cevap vererek uygun ürünlerin üretilmesi gerekmektedir.

4.2. Önemi

Tedarik zincirinde depolanan verilerin kullanılması işletmelerin kar elde etmesi, müşteri memnuniyeti sağlama ve rekabet etmesine dair incelemeler yapılmasında bir fırsat oluşturmaktadır. Tedarik zincirindeki veriler ile daha hızlı ve verimli işlemlerin yapılması işletmenin işleyişinde ve yönetilmesinde fayda sağlamaktadır. İşletmeler bu durumda daha dinamik kararlar alarak müşterinin memnun edilmesini amaçlayarak kar elde etmektedir. Böylelikle tedarik zincirinde veriler ile tahmin yapılabilmesine dair incelemeler yapılarak önemi ortaya konacaktır.

4.3. Amaç

Tedarik zincirinde kullanılan uygulamaların veri tabanlarında depoladıkları veriler ile tahminler yapılmasını ve bu tahminler doğrultusunda tedarik zincirinde planlamalar yapılması gerektiği sunulmaktadır. Böylelikle işletmeler tedarik zincirini etkin ve verimli kullanarak rekabet ortamında daha aktif faaliyetler içerisinde bulunmalarını sağlamaktadır.

4.4. Sınırlılıklar

Araştırma <https://www.kaggle.com/datasets/> veri tabanından bulunan tedarik zincirinde araba satışı verisindeki 23906 veri ile sınırlıdır.

Araştırmada ele alınan veriler yapılandırılmış ve yapılandırılmamış olmak üzere iki sınıflandırma ile sınırlıdır.

Araştırmada araştırmacı tarafından uygulanacak olan Weka programındaki algoritmaların sınıflandırması ile elde edilen analizlerle sınırlıdır.

4.5. Yöntem

Bu bölümde internet üzerinden erişim sağlanan ücretsiz, açık kaynak olan Kaggle (<https://www.kaggle.com/datasets/>) veritabanından temin edilen tedarik zincirinde araba satışı veri seti kullanılacaktır. Veri kümesinin (.csv ve .arff) dosyaları Kaggle üzerinde indirilip Türkçe'ye çevrilerek kullanımı sağlanacaktır. Çalışmada, WEKA programının Explorer modülünde bulunan Decision Tree (J48), Naive Bayes, KNN, LWL, Bagging ve Adaboost M1 algoritmaları ile sınıflandırma yapılacaktır. Veri setinin menşei tedarik zincirindeki araba satışlarının kayıtlarıdır. Veri kümesinde 23906 adet gözlem verisi yer almaktadır. Veri kümesinde yer alan 23906 değişken değeri ile araba satışlarındaki tedarik zinciri tahminlemesi yapılacaktır.

4.6. Kullanılan Sınıflandırma Algoritmaları

4.6.1. Decision Tree (J48)

1993'te ID3 algoritmasını geliştirmiş olan Quinlan tarafından C4.5 algoritması ID3'ün geliştirilmiş sürümü olarak ortaya çıkmıştır (Gürsoy, 2019). C4.5 algoritması ID3'te bulunan eksiklikleri gidermek için geliştirilmiştir (Gürsoy, 2019). Özellikle kategorik olan verilerle çalışan ID3'ün aksine C4.5 algoritması istatistikî verilerle çalışmaktadır (Özdemir & Ballı, 2020). C4.5 algoritması ile en bilinen karar ağacı yapıları oluşturulmaktadır (Kunt, 2019). Ağaç yapılarında kabul edilmesi ve açıklanması kolay, veri kümelerinin aktif bir şekilde kullanılması için karar ağaçları sınıflandırıcısı kullanılmaktadır (Küçükönder vd., 2015). Bu algoritmanın önemli avantajları arasında bulunmakta olan sınıf yapılarının önceden belirlenen sınıf yapılarıyla oluşturulmuş kategorik veri yapılarında sınıfı bilinmemekte olan verilerin hangi sınıfa ait olduklarını tahmin ederek, veriyi ağaç modellemesi ile görselleştirir ve

öznitelikler arasındaki bağlantıların kolay bir şekilde modellenmesini sağlamaktadır. (Küçükönder vd., 2015).

Bilgi Kazancı (Information Gain): ID3, C4.5 gibi karar ağacı metotlarında en ayırt edici niteliği belirlemek için her bir nitelik için bilgi kazancı ölçmektedir. Bu bilgi kazancı ölçümünde Entropy kullanılmaktadır. Entropy rastgeleliği, belirsizliği ve beklenmeyen durumun ortaya çıkma olasılığını göstermektedir.

$$Entropy = \sum_{i=1}^c -P_i * \log_2(P_i)$$

4.6.2. Naive Bayes

Naive Bayes algoritması genellikle etkinliği ve basitliği nedeniyle değer görsede, dikkate alınması gereken önemli sınırlamaları olmaktadır (Raschka, 2014). Bu sınıflandırma yöntemi, gerçek dünya veri kümelerinde sıklıkla ihlal edilen özelliklerin bağımsızlığı gibi güçlü varsayımlara dayanmaktadır (Wickramasinghe & Kalutarage, 2020). Ayrıca, Naive Bayes eğitim verilerinin kalitesine ve dağılımına duyarlı olabilir ve temel varsayımlar karşılanmadığında düşük performansla yol açabilmektedir (Kelly & Johnson, 2021). Naive Bayes daha karmaşık ve esnek makine öğrenimi teknikleri, özellikle karmaşık, yüksek boyutlu veya gürültülü verilerle uğraşırken birçok veri madenciliği görevi için daha uygun olmaktadır (Zhong vd., 2020).

Naive Bayes, belirli durumlarda hala değerli bir araç olabilmektedir. Özellikle spam filtreleme veya metin kategorizasyonu gibi hızlı ve verimli sınıflandırma görevleri için yararlı olabilir, burada bağımsızlık varsayımı oldukça iyi bir şekilde tutulabilmektedir (Raschka, 2014). Naive Bayes, daha gelişmiş modellerle daha da geliştirilebilecek iyi bir temel performans da sağlayabilmektedir (Metsis vd., 2006). Naive Bayes kullanırken, eldeki verileri ve problemi dikkatlice değerlendirmek ve altta yatan varsayımların karşılanıp karşılanamayacağını göz önünde bulundurmak önemli olmaktadır (Seewald, 2007). Naive Bayes algoritması, doğru uygulama ve sınırlamalarının dikkate alınmasıyla, veri madenciliği uygulayıcılarının araç setinde değerli bir bileşen olabilmektedir (Wickramasinghe & Kalutarage, 2020).

Naive Bayes ile özellik bağımsızlığı varsayımı, özellikle yüksek boyutlu veya korelasyonlu verilerle uğraşırken yanlış ve yanlış olasılık tahminlerine yol açabilmektedir (Uzun vd., 2018). Ayrıca, Naive Bayes eğitim verilerinin kalitesine ve dağılımına duyarlı olabilir ve temel varsayımlar karşılanmadığında düşük performansa yol açabilmektedir (Rennie, 2001). Bu gibi durumlarda, karar ağaçları, rastgele ormanlar veya destek vektör makineleri gibi daha karmaşık ve esnek makine öğrenimi teknikleri, özellikle karmaşık, yüksek boyutlu veya gürültülü verilerle uğraşırken birçok veri madenciliği görevi için daha uygun olabilmektedir (Seylan vd., 2020).

Naive Bayes algoritmasının hesaplanması için aşağıdaki formül kullanılmakta;

$$P(Y = y_i | X = x_k) = \frac{P(X = x_k | Y = y_i)P(Y = y_i)}{\sum_j P(X = x_k | Y = y_j)P(Y = y_j)}$$

Kaynak: Demir, 2018.

Bu formül yeni bir gözlem değeri olan yani X geldiğinde Y'nin herhangi bir değerinin ortaya çıkma olasılığına bakılarak hesaplanabilmesi ile en büyük değer seçilerek istenilen sonuca ulaşılmış olunacaktır (Demir, 2018). Bu durum şu şekilde hesaplanmakta; (Y'nin değerini i olarak kabul ettiğimizde, yeni değer olan X'in ortaya çıkma olasılığı) * (Y'nin ise i olma olasılığı) / (Y'nin ortaya çıkan her bir değeri için ise yeni elde edilen X değerinin ortaya çıkma olasılıklarını, Y'nin ise o değerini ortaya çıkarma olasılığının çarpımlarının toplamı) ve paydada ise paydaki her bir Y değeri için yazılan ve bunların toplanarak hesaplanmasını sağlamaktadır (Demir, 2018).

4.6.3 LWL (Locally Weighted Learning- Yerel Ağırlıklı Öğrenme)

Yerel Ağırlıklı Öğrenme (LWL), yakındaki veri noktalarının ağırlıklı toplamını dikkate alarak bir hedef değişkeni tahmin eden bir regresyon algoritmasıdır (<https://www.cs.cmu.edu/>). Tek bir global fonksiyona uyan standart regresyon modellerinin aksine, LWL her tahmin noktası için ayrı bir modele uyarlanmaktadır (Klanke vd., 2008). Bu, algoritmanın modeli girdi uzayının yerel yapısına uyarlayarak verilerdeki doğrusal olmayan ilişkileri yakalamasını sağlamaktadır (Frank vd., 2002). LWL'deki temel adımlar şunlardır: 1) belirli bir tahmin noktası için eğitim verilerindeki k en yakın komşuyu bulmak; 2) tahmin noktasına yakınlığına göre her komşuya ağırlık atamak; 3) tahmini komşuların hedef değerlerinin ağırlıklı ortalaması olarak

hesaplamaktır (Frank vd., 2002). Bu esnek ve uyarlanabilir yaklaşım, LWL'yi altta yatan fonksiyonun karmaşık ve doğrusal olmadığı çok çeşitli regresyon problemleri için uygun hale getirmektedir (Centner ve Massart, 1998).

LWL belirli bir sorgu noktasına göre uyarlanmış yerel bir model öğrenmeye odaklanmaktadır (Atkeson vd., 1997). LWL'nin kilit yönleri, ağırlıklandırma şemasını tanımlamak için bir çekirdek fonksiyonunun kullanılması ve yüksek boyutlu özellik uzaylarında bile doğru tahminler sağlama yeteneği bulunmaktadır (Vijayakumar vd., 2005). Yakındaki, ilgili veri noktalarının katkısını vurgulayarak, LWL heterojen veya seyrek veri dağılımlarıyla etkili bir şekilde başa çıkabilir ve bu da onu çeşitli regresyon görevleri için güçlü bir araç haline getirmektedir (Klanke vd., 2008).

Aşağıdaki formül kullanılmakta;

$$J = \frac{1}{2} \sum_{i=1}^n w_i (x_q) (Y_i - X_i \beta_q)^2$$

Kaynak: Englert, 2012.


- ❖ Etiketli eğitim verileri $D = \{(x_i, y_i) \mid i = 1, 2, \dots, n\}$ burada her veri noktası x_i karşılık gelen bir çıktı değeri Y_i 'ye aittir.
- ❖ İlgili noktası x_q (sorgu noktası olarak da adlandırılır), Y^q tahminini istenilen konumdadır.
- ❖ w_i Ağırlıkları, mevcut tahmin için ilgili eğitim setinin (x_i, y_i) uygunluğunu tanımlamakta ve bu sorgu noktasına bağlıdır ve bir ağırlıklandırma fonksiyonu ile hesaplanmaktadır.
- ❖ Tahmin yapmak için elde etmek istediğimiz doğrusal modelimizin regresyon katsayısı β_q (Englert, 2012)

4.6.4. IBk (K-en yakın komşu, k-nearest neighbour)

k-en yakın komşu (k-NN) algoritması, sınıflandırma ve regresyon görevleri için kullanılan basit ancak güçlü bir denetimli makine öğrenimi algoritması olmaktadır (Mucherino vd., 2009). Belirli bir girdiye en yakın k veri noktasını bularak ve ardından girdinin etiketini veya değerini tahmin etmek için bu komşuların sınıf etiketlerini veya değerlerini kullanarak çalışmaktadır (Jivani, 2013).

k-en yakın komşu (k-NN) algoritması, sınıflandırma ve regresyon görevleri için kullanılan temel bir makine öğrenimi tekniği olmaktadır. Sınıflandırma için algoritma, girdiyi k en yakın komşular arasında en yaygın olan sınıfa atamaktadır (Jivani, 2013). Regresyon için algoritma, k en yakın komşunun değerlerinin ortalamasını veya ağırlıklı ortalamasını tahmin etmektedir (Mucherino vd., 2009).

Şekil 20: k-en yakın komşu algoritması örneği



Kaynak: Şeker, 2008.

k-NN algoritması anlaşılması ve uygulanması kolaydır, ancak girdi ile diğer tüm veri noktaları arasındaki mesafelerin hesaplanmasını gerektirdiğinden büyük veri kümeleri için hesaplama açısından pahalı olabilmektedir (Bhardwaj vd., 2018). Ayrıca, k parametresinin ve mesafe metriğinin seçimi algoritmanın performansı üzerinde önemli bir etkiye sahip olabilmektedir (Celebi vd., 2013). KNN ayrıca, boyut sayısı arttıkça “en yakın komşu” kavramı daha az anlamlı hale geldiğinden, yüksek boyutlu verilerle de mücadele etmektedir (Cunningham ve Delany, 2007). KNN tembel bir öğrenme algoritmasıdır, yani hesaplamayı tahmin aşamasına erteler, bu da özellikle büyük veri kümeleri için daha yavaş yanıt sürelerine yol açabilmektedir (Cunningham ve Delany, 2021). KNN algoritması parametrik değildir, yani altta yatan veri dağılımı hakkında herhangi bir varsayımda bulunmamaktadır. Bunun yerine, tahminlerde bulunmak için veri noktalarının yakınlığına güvenmektedir (Hamerly ve Elkan, 2003). KNN, görüntü tanıma, spam tespiti ve kredi riski analizi dahil olmak üzere çeşitli sorunlara uygulanabilen çok yönlü bir algoritma olmaktadır (Mukid vd., 2018).

4.6.5. Bagging

“Bootstrap aggregating “in kısaltması olan Bagging algoritması, makine öğrenimi algoritmalarının kararlılığını ve doğruluğunu artıran güçlü bir topluluk öğrenme tekniklerinden biridir (<https://www.cs.cmu.edu/>). Daha sağlam ve güvenilir bir tahmin yapmak için her biri eğitim verilerinin rastgele bir alt örneği üzerinde eğitilmiş birden fazla temel modelin tahminlerini birleştirerek çalışmaktadır (Tüysüzöğlü ve Birant, 2020). Bu yaklaşım, bireysel modellerin varyansını azaltmaya yardımcı olarak daha iyi genelleme performansı sağlamaktadır. Bagging algoritması, eğitim verilerine aşırı uyum sağlamaya eğilimli olabilen karar ağaçları için özellikle etkili olmaktadır (Breiman, 1996). Bagging algoritması, birden fazla karar ağacının tahminlerinin ortalamasını alarak, eğitim setinin özelliklerine daha az duyarlı olan daha istikrarlı ve doğru bir model oluşturabilmektedir (Buja & Stuetzle, 2006). Ayrıca, bootstrap örneklemesinin kullanılması, her bir temel modelin verilerin benzersiz bir alt kümesi üzerinde eğitilmesini sağlayarak topluluğu daha da çeşitlendirir ve verilerdeki altta yatan kalıpları yakalama yeteneğini geliştirmektedir (Breiman, 1996).

Bagging algoritması, model performansını iyileştirmedeki avantajlarına rağmen, bazı sınırlamaları vardır (Grandvalet, 2004). Ana dezavantajlardan biri, altta yatan temel modellerin doğasında bulunan önyargıları artırma eğilimidir. Bagging algoritması, birden fazla zayıf öğrencinin tahminlerini bir araya getirdiğinden, temel modellerin doğasında bulunan sistematik önyargılar birleşerek potansiyel olarak optimal olmayan ve hatta yanıltıcı sonuçlara yol açabilmektedir (Buja & Stuetzle, 2006). Ayrıca, bagging algoritması, yaklaşımı özellikle büyük veri kümeleri veya karmaşık temel modellerle uğraşırken hesaplama açısından yoğun olabilir ve bu da belirli senaryolarda pratik uygulanabilirliğini sınırlayabilmektedir (Davidson & Fan, 2006). Bagging algoritması güçlü bir teknik olmakla birlikte, gerçek dünya problemlerine uygulanırken sınırlamaları dikkatle değerlendirilmektedir.

Aşağıdaki hesaplama yöntemini kullanmakta;

$$f(x) = \frac{1}{B} \sum_{b=1}^B f_b(x)$$

Kaynak: <https://medium.com/>

4.6.6. Adaboost M1

Adaptive Boosting'in kısaltması olan Adaboost M1, güçlü bir sınıflandırıcı oluşturmak için birden fazla temel sınıflandırıcıyı birleştirerek çalışan güçlü bir sınıflandırma algoritmasıdır (<https://weka.sourceforge.io/>). Özellikle karmaşık veri setlerinin işlenmesinde etkilidir ve temel sınıflandırıcıların performansını, verileri doğru bir şekilde sınıflandırma yeteneklerine göre farklı ağırlıklı veriler atayarak artırabilmektedir (Hasan vd., 2015).

Adaboost M1'in en önemli özelliklerinden biri, her yanlış sınıflandırılmış verilerin önceki hatalarına göre eğitildiği yinelemeli yapısı vardır (Chengsheng vd., 2017). Bu, algoritmanın her bir yinelemede yanlış sınıflandırılmış veri noktalarına daha fazla odaklanmasını sağlayarak daha doğru bir genel sınıflandırma modeline yol açmaktadır (Xie, 2009).

Adaboost M1 hem kategorik hem de sayısal girdi verilerini işleyebilir, bu da onu çok çeşitli sınıflandırma görevleri için çok yönlü bir seçim haline getirmektedir (Kang ve Michalak, 2018).

Adaboost M1 sınıflandırıcısının denkleminin son kullanım hali aşağıdaki gibidir:

$$H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t h_t(x) \right)$$

Kaynak: Freund ve Schapire, 1997.

4.7. Performans Ölçümleri

4.7.1 Kappa İstatistiği

Kappa istatistiği, her biri bir dizi maddeyi birbirini dışlayan kategoriler halinde sınıflandıran iki puanlayıcı veya gözlemci arasındaki uyumu değerlendirmek için istatistiksel bir ölçüt olarak kullanılır (McGinn vd., 2004). Kappa, şans eseri beklenen anlaşmayı hesaba katarak basit yüzde anlaşmasından daha sağlam bir anlaşma ölçüsü sağlamaktadır (Franco & Napoli, 2016). Kappa istatistiği, şans eseri beklenenin ötesindeki uyum düzeyini ölçerek araştırmacılara değerlendirmelerinin güvenilirliği ve tutarlılığı hakkında daha iyi bir anlayış sağlamaktadır (Viera & Garrett, 2005).

Kappa istatistiği tıbbi teşhis, içerik analizi ve sosyal bilim araştırmaları gibi çeşitli alanlarda yaygın olarak kullanılmaktadır. Kappa istatistiği kategorik verilerin güvenilirliğini

değerlendirmek için yaygın olarak kullanılsa da dikkate alınması gereken bazı sınırlamaları bulunmaktadır (McHugh, 2012). Kappa istatistiği, güvenilirlik açısından daha sağlam bir ölçüm sağlar. Kappa istatistiği -1 ile 1 arasında değişir; burada 1 mükemmel uyumu, 0 şanstan daha iyi olmayan uyumu ve negatif değerler şanstan daha az uyumu göstermektedir (Flight & Julious, 2014).

Tablo-1: Kappa katsayı değer aralıklarına göre yorumlama tablosu

Kappa Değer Aralığı	Yorum
<0,00	Ters/Kötü Uyum
0.01-0.20	Önemsiz Uyum
0.21-0.40	Zayıf Uyum
0.41-0.60	Orta Düzeyde Uyum
0.61-0.80	İyi Düzeyde Uyum
0.81-1.00	Çok İyi Düzeyde Uyum

Kaynak: Landis ve Koch, 1977.

4.7.2. Karmaşıklık matrisi (Confussion Matrix)

Veri Madenciliğinde sınıflandırma modellerinin performansını değerlendirmek için hedef niteliğe ait tahminlerin ve gerçek değerlerin karşılaştırıldığı matrise karmaşıklık matrisi (confussion matrix) denilmektedir. Karmaşıklık matrisi (Confussion Matrix) ile araştırma yapılan verilerin sınıflandırma modelleri ile elde edinilen sonuçları doğrultusunda yorum yapılabilmesi için gerçek ve tahmin edinilen veriler arasındaki ilişkilerde yer alan hataları çapraz olarak inceleyerek oluşturulmaktadır (Şener, 2020). Veri kümesindeki verilerin sınıflandırma modeline uygun olarak doğru ve yanlış tahmin edilebilmesi karmaşıklık matrisi değerlerini Tablo 2’de gösterilmektedir (Küçük, 2021).

Karmaşıklık matrisi, modelin yanlış sınıflandırmalarındaki kalıpların belirlenmesine yardımcı olarak modelde gelecekte yapılacak iyileştirmelere ve geliştirmelere rehberlik edebilmektedir. Genel olarak, karmaşıklık matrisi, verilerin incelenmesi için araç setinde güçlü ve vazgeçilmez bir araçtır, sınıflandırma modellerinin kapsamlı bir şekilde değerlendirmekte ve daha sağlam ve doğru tahmin sistemlerinin geliştirilmesini sağlamaktadır.

Tablo-2: Karmaşıklık matrisi (Confussion Matrix)

Karmaşıklık Matrisi (Confussion Matrix)		Gerçek Sonuçlar	
		Pozitif	Negatif
Tahmin Edilen Sonuçlar	Pozitif	TP True Pozitif	FP False Pozitif
	Negatif	FN False Negatif	TN True Negatif

TP (True Pozitif)-Gerçek Pozitif: Sınıflayıcının ne kadar gerçek pozitif değeri doğru tahmin ettiğinin bir ölçüsüdür. Olumlu tahmin edilen doğru olarak bulunmaktadır. Hesaplama yöntemi aşağıdaki gibidir.

$$TP = \frac{TP}{TP + FN}$$

TN (True Negatif)-Gerçek Negatif: Sınıflayıcının ne kadar gerçek negatif değeri doğru tahmin ettiğinin bir ölçüsüdür. Özgüllük veya Seçicilik olarak da bilinmektedir. Olumsuz tahmin edilen bu doğru olarak bulunmaktadır. Hesaplama yöntemi aşağıdaki gibidir.

$$TN = \frac{TN}{TN + FN}$$

FP (False Pozitif)-Yanlış Pozitif: Gerçek değeri 0 olmasına karşın 1 olarak tahmin edilenlerin oranıdır. Olumlu tahmin edilen yanlış olarak bulunmaktadır. Hesaplama yöntemi aşağıdaki gibidir.

$$FP = \frac{FP}{TP + FP}$$

FN (False Negatif)-Yanlış Negatif: Gerçek değeri 1 olmasına karşın 0 olarak tahmin edilenlerin oranıdır. Kayıp oranı olarak da bilinir. Olumsuz tahmin edilen yanlış olarak bulunmaktadır. Hesaplama yöntemi aşağıdaki gibidir.

$$FN = \frac{FN}{TP + FN}$$

Çok sınıflı sınıflandırma performans ölçümleri için karmaşıklık matrisini kullanarak modelin hesaplanması sonucunda Ortalama Doğruluk, Ortalama Hata Oranı, Ortalama Hatırlama, Ortalama Hassasiyet ve Ortalama F1-Skoru için hesaplama formülleri tablo 3’de yer almaktadır.

Tablo-3: Çok Sınıflı Sınıflandırma İçin Performans Ölçüm Metriği ve Hesaplama Formülleri

Performans Ölçüm Metriği	Formül
Ortalama Doğruluk (Averaged Accuracy)	$\frac{\sum_{i=1}^l \frac{TP_i + TN_i}{TP_i + FN_i + FP_i + TN_i}}{l}$
Ortalama Hata Oranı (Averaged Error Rate)	$\frac{\sum_{i=1}^l \frac{FP_i + FN_i}{TP_i + FN_i + FP_i + TN_i}}{l}$
Ortalama Hatırlama (R_m) (Averaged Recall)	$\frac{\sum_{i=1}^l \frac{TP_i}{TP_i + FN_i}}{l}$
Ortalama Hassasiyet (P_m) (Averaged Precision)	$\frac{\sum_{i=1}^l \frac{TP_i}{TP_i + FP_i}}{l}$
Ortalama F1-Skoru (Averaged F-Measure)	$\frac{2 * R_m * P_m}{R_m + P_m} = \frac{\frac{\sum_{i=1}^l \frac{TP_i}{TP_i + FN_i}}{l} * \frac{\sum_{i=1}^l \frac{TP_i}{TP_i + FP_i}}{l}}{\frac{\sum_{i=1}^l \frac{TP_i}{TP_i + FN_i}}{l} + \frac{\sum_{i=1}^l \frac{TP_i}{TP_i + FP_i}}{l}}$

Kaynak: Hossin & Sulaiman, 2015.

Ortalama Doğruluk: Doğru pozitif oranı ile doğru negatif oranlarının tüm sınıflandırma değerlerine olan oranlar ile bölünerek bulunmaktadır.

Ortalama Hata Oranı: Yanlış pozitif oranı ile yanlış negatif oranlarının tüm sınıflandırma değerlerine olan oranları ile bölünerek bulunmaktadır.

Ortalama Hatırlama: Doğru pozitif oranının yanlış negatif ve doğru pozitif oranlarına bölünerek bulunmakta ve pozitif durumların ne kadar başarılı olduğu gösterilmektedir.

Ortalama Hassasiyet: Doğru pozitif oranının yanlış pozitif ve doğru pozitif oranlarına bölünerek bulunmakta ve pozitif olarak tahmin edilen sınıflandırmanın başarısını göstermek için kullanılmaktadır.

Ortalama F1-Skoru: Ortalama hatırlama ve ortalama hassasiyet oranlarının harmonik ortalaması alınarak sınıflandırmanın ne kadar iyi performans da olduğunu göstermektedir.

4.8. Çapraz Doğrulama

Makine öğrenmesinin görmediği veriler üzerindeki performansları nesnel ve doğru bir şekilde değerlendirilmesi için çapraz doğrulama (cross-validation) kullanılarak yeni bir örneklem oluşturulmaktadır (Bayram Durna, 2020). Veri kümelerini parçalara ayırarak eğitilmesi ve sınıflandırma modellerinin değerlendirmesini sağlayan k-Fold cross validation ile hesaplanmaktadır (Şirin, 2017).

k-Fold Cross validation değeri kullanıcı tarafından ne kadar olduğu manuel olarak girilir ve k adet kadar sınıflandırma işlemi yapılır ve her bir adım için bölünmüş olan parçalardan bir tanesi test işlemi için ayrılır ve geride kalmış olan k-1 tanesi için sınıflandırmanın eğitilmesi için kullanılmaktadır (Çınar, 2017). Daha sonrasında k adım ile elde edilen sınıflandırmaların ortalamaları alınarak genel bir sınıflandırma sonucu ortaya konulmaktadır (Çınar, 2017).

Çapraz doğrulama, eğitim setinin boyutunu azaltmadan modelin mevcut tüm örnekler üzerinde değerlendirilmesine olanak tanımaktadır. Çapraz doğrulama, makine öğrenimi modellerinin performansını değerlendirmek için kullanılan güçlü bir tekniktir. Çapraz doğrulama sınıflandırma, regresyon ve kümeleme gibi çok çeşitli makine öğrenimi görevlerine uygulanabilir. Belirli bir sorun için en uygun hiper parametrelerin veya model mimarisinin belirlenmesine yardımcı olabileceğinden, model seçimi için de değerli bir araçtır.

Örnek olarak k değerinin 10 olarak girilmesi ile belirlenecek olan çapraz doğrulama işlemi Şekil 21’de gösterilmektedir (Çınar, 2017).

Şekil-21: Çapraz Doğrulama (k-Fold Cross validation)

	1. Parça	2. Parça	3. Parça	4. Parça	5. Parça	6. Parça	7. Parça	8. Parça	9. Parça	10. Parça
1. Adım	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
2. Adım	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
3. Adım	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
4. Adım	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
5. Adım	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim
6. Adım	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim
7. Adım	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim
8. Adım	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim
9. Adım	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim
10. Adım	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test

Kaynak: Çınar, 2017

Girilmiş olan 10 değeri ile parçalara bölünen veri kümesinde 9 adet eğitim verisi ve geride kalan diğer parça değerleri ise test verisi olarak kullanılmıştır ve bu 10 aşamada meydana gelen her bir adımda farklı bir test parça değeri kullanılarak hesaplanmaktadır (Çınar, 2017).

$$Genel\ Sonuç = \frac{1}{k} \sum_{i=1}^k Sonuç_i$$

Denklemden yer alan;

k : Kullanıcı tarafından belirlenen bölünme sayısını,

$Sonuç_i$: Tur sonucu elde edilen başarı oranını göstermektedir.

4.9. Veri Seti

Çalışmada kullanılan veri setini anlama, veri seti ön işleme, veri seti düzenleme ve model oluşturma süreçleri gerçekleştirilecektir. Bu işlem süreçlerinden sonra veriler; analiz edilebilir ve sonuç elde edilebilir hale gelmesi sağlanmaktadır.

Bu veri seti toplam 23906 tane kayıttan oluşmaktadır. Bu kayıtlar kategorik ve sayısal özellikler olarak 16 tanedir ve 2022-2023 yılları arasında gerçekleştirilen satışları kapsamaktadır. Fakat veri setinde bulunan fazlalıklar ve detaylar olması nedeniyle veriler ön

işleme sürecinden geçirilmektedir. Bu değişkenler müşteri adı, tarih, cinsiyet, yıllık gelir, şirket ve bayi bölgesi gibi özellikler mevcuttur.

4.9.1. Veri Ön İşleme

Veri ön işleme, etkili veri analizi ve modelleme için temel oluşturduğundan veri analizi işlem hattında kritik bir adımdır. Bu süreç, ham verilerin daha fazla analiz için uygun bir formata dönüştürülmesini, veri kalitesinin sağlanmasını ve verilerin analiz iş akışının sonraki adımları için hazırlanmasını içermektedir. Veri ön işleme sırasında, eksik değerlerin ele alınması, kategorik değişkenlerin yapılandırılması ve sayısal özelliklerin ölçeklendirilmesi gibi yaygın görevler söz konusu olabilmektedir.

Bu bölümde veri temizleme, düzenleme ve veri tipi dönüşümü işlemleri yapılacaktır.

4.9.2. Veri temizleme ve düzenleme

Kullanılan veri setindeki verilerin ham halinden “Musteri_Adi”, “Bayi_Numarası” ve “Telefon” değişkenleri yapılan analizler için anlamsız olduğu ve “Araba İd”, değişkeninin tüm veri seti için sabit olduğu gözlemlenmiştir. Uygulamada kullanılan veri seti kontrol edilmiş ve eksik veri içermediği görülmüştür.

Veri setinde bulunan müşterinin yıllık geliri belirli aralıklara bölünerek nominal değişkene dönüştürülmüştür. Bu değişken “Yillik_Gelir_Araligi” başlığı altından tekrar düzenlenmiştir. Bu yıllık gelir aralığı oluşturulurken aynı yıllık gelire sahip olan müşteriler tespit edilmiş ve veriler belirli eşit aralıklara bölünerek incelenmiştir. Bu aralıklar müşterinin en düşük yıllık geliri en alt sınır olarak belirlenmiş olup ve en yüksek yıllık geliri ise en üst sınır olarak belirlenmiştir. Bu durumda Weka’da incelenmesi için şu şekilde bölünmüştür;

- A= 10080-639000
- B= 640000-1016000
- C= 1017000-1675000
- D= 1679000-11200000

Bu bölünmenin yapılma amacı verinin boyutunu azaltarak daha iyi sonuçların verilmesi sağlanmıştır. Böylelikle çalışmada kullanılan veri seti 16 değişkenden 13 değişkene indirgenmiştir.

Tüm bu işlemler gerçekleşikten sonra veri seti Weka'nın dosya uzantısı olan .arff'ye dönüştürülmüştür.

4.9.3. Veri Tipi Dönüşümü

Bu aşamada, verilerin analizi yapılması için veriler dönüştürülmüştür. Veri madenciliği analizi için Weka Programı 3.8.6 versiyonu kullanılmıştır. Weka'da veri analizi yapılması için dosya uzantısı olan .csv'den .arff'ye veriler dönüştürülmüştür. Değişkenlerin veri tipi dönüşümü aşağıda gösterildiği gibidir.

Değişken 1: Tarih nominal

Değişken 2: Cinsiyet {Erkek,Kadin}

Değişken 3: 'Yillik Gelir' numeric

Değişken 4: 'Yillik Gelir Araligi' nominal

Değişken 5: Sirket (Marka) {Ford, Dodge, Cadillac, Toyota, Acura, Mitsubishi, Chevrolet, Nissan, Mercury, BMW, Chrysler, Subaru, Hyundai, Honda, Infiniti, Audi, Porsche, Volkswagen, Buick, Saturn, Mercedes-B, Jaguar, Volvo, Pontiac, Lincoln, Oldsmobile, Lexus, Plymouth, Saab,Jeep}

Değişken 6: Model nominal

Değişken 7: Motor {'Ustten Cift Eksantrik Mili','Ustten Eksantrik Mili'}

Değişken 8: Vites {Otomatik, Manuel}

Değişken 9: Renk {Siyah, Kirmizi, 'Kirik Beyaz'}

Değişken 10: Fiyat numeric

Değişken 11: Govde_Stili {SUV,Passenger,Hatchback,Hardtop,Sedan}

Değişken 12: Bayi_Adi {'Buddy Storbecks Diesel Service Inc','C - M Motors Inc','Capitol KIA','Chrysler of Tri-Cities','Chrysler Plymouth','Classic Chevy','Clay Johnson Auto Sales','U-Haul CO','Rabun Used Car Sales','Race Car Help','Saab-Belle Dodge','Scrivener Performance Engineering','Diehl Motor CO Inc','Star Enterprises Inc','Suburban Ford','Tri-State Mack Inc','Progressive Shippers Cooperative Association No','Ryder Truck Rental and

Leasing','Enterprise Rent A Car','Gartner Buick Hyundai Saab','Hatfield Volkswagen','Iceberg Rentals','McKinney Dodge Chrysler Jeep','Motor Vehicle Branch Office','Nebo Chevrolet','New Castle Ford Lincoln Mercury','Pars Auto Sales','Pitre Buick-Pontiac-Gmc of Scottsdale'}\}

Değişken 13: Bayi_Bolgesi {Middletown, Aurora, Greenville, Pasco, Janesville, Scottsdale, Austin}

4.10. Araştırma Bulguları

Bu çalışmada kullanılan veri seti iki farklı bağımlı değişken ile incelenmiştir. Birincisi bayi bölgesine göre sınıflandırma algoritmalarının başarıları, ikinci olarak da yıllık gelir aralığına göre sınıflandırma algoritmalarının başarıları incelenmiştir. Ayrıca eğitim ve test veri kümeleri %66 eğitim, %33 test olarak ayrılarak hesaplanmıştır.

D1 veri seti: Bağımlı değişken olan “bayi bölgesi” üzerinde etkisi olan 11 özneliğin olduğu tespit edilmiştir. Bu öznelikler;

- Tarih
- Cinsiyet
- Yıllık Gelir
- Şirket (Marka)
- Model
- Motor
- Gövde Stili
- Vites
- Renk
- Fiyat
- Bayi Adı

D2 veri seti: Bağımlı değişken olan “Yıllık Gelir Aralığı” üzerinde etkisi olan 8 özneliğin olduğu tespit edilmiştir. Veri setine etki eden öznelikler;

- Cinsiyet
- Yıllık Gelir
- Şirket (Marka)

- Model
- Motor
- Gövde Stili
- Vites
- Renk

D1 ve D2 veri setleri için seçilen özniteliklerin amacı; veri setinin boyutunu azaltmak, model performanslarını arttırmak ve zamandan tasarruf etmektir.

4.10.1. Sınıflandırma Algoritmaları ve Değerlendirmeler

Bu çalışmada, kullanılan sınıflandırma algoritmalarının performans ölçüm metrikleri açısından değerlendirmeler yapılmıştır. Tedarik zincirinde araba satışlarının hangi bayi bölgesi ve hangi yıllık gelir aralığı üzerinden gerçekleştiği incelenmiştir.

4.10.1.1. D1. Decision Tree (J48) Sonuçları

Bağımlı değişken olan bayi bölgesi üzerinde etkisi olan 11 özniteliğin etkisi olduğu tespit edilmiş olup ve Decision Tree (J48) algoritmasından elde edilen sonuçlar, 6460 veri doğru olarak sınıflandırılmış fakat 1668 veri ise yanlış sınıflandırılmıştır. Karmaşıklık matrisinden Tablo-4 elde edilmiştir. Algoritmaya ait kappa katsayısı 0.7603 olarak elde edilmiş ve kappa katsayı değer aralıklarına göre iyi düzeyde uyum içerisindedir. Karar Ağaçları (Decision Tree) karmaşıklık matrisine göre verilen sonuçlar incelendiğinde en düşük doğruluk değerlerine sahip olan Bayi 1, Bayi 2, Bayi 3, Bayi 4, Bayi 6 ve Bayi 5 takip etmiştir. En yüksek doğruluk değerini Bayi 7 vermiştir.

Decision Tree (J48) sınıflandırma algoritması eğitim olarak %66 ve test olarak da %33 ayrılarak 79.4783 % doğrulukla tahmin edilmiştir.

Tablo-4: Decision Tree (J48) Algoritması Karmaşıklık Matrisi

		Tahmini Sınıf						
		Bayi 1	Bayi 2	Bayi 3	Bayi 4	Bayi 5	Bayi 6	Bayi 7
Gerçek Sınıf	Bayi 1	849	38	35	23	50	40	28
	Bayi 2	32	858	29	34	37	42	39
	Bayi 3	35	31	875	35	42	38	49
	Bayi 4	36	25	25	858	45	45	34
	Bayi 5	31	47	38	35	1012	45	40
	Bayi 6	28	27	38	26	34	940	41
	Bayi 7	45	47	44	47	51	137	1068

Tablo-5: Decision Tree (J48) Algoritması Performans Sonuçları

Değerlendirme metriği	Metrik Değeri Yüzde (%)
Ortalama Doğruluk	79,5
Ortalama Hata Oranı	3,4
Ortalama Hatırlama	79,5
Ortalama Hassasiyet	79,7
Ortalama F1-Skoru	79,5

Decision Tree (J48) algoritması ile gerçekleştirilen sınıflandırma işlemi sonucunda elde edilen farklı değerlendirme metrik değerleri Tablo-5 'te verilmiştir. Değerlendirme metrik sonuçları, ortalama doğruluk oranı 79,5% olarak bulunmakta ve doğru sınıflandırılan verilerin toplama bölümü sonucunda elde edilen veridir. Ortalama Hata oranı 3,4% olarak bulunmuştur ve yanlış sınıflandırılan verilerin toplama bölümü sonucu elde edilen verilerdir. Ortalama hatırlama oranı 79,5% olarak bulunmuş ve pozitif durumların ne kadar başarılı olduğu tahmin edilmiştir. Ortalama hassasiyet oranı 79,7% oranı olarak bulunmuş ve pozitif olarak tahmin edilen sınıflandırmanın başarısını göstermektedir. Ortalama F1-Skor oranı ortalama hatırlama ve ortalama hassasiyet oranlarının harmonik ortalaması alınarak 79,5% olarak bulunmuş ve sınıflandırmanın ne kadar iyi performans gösterdiğinin ölçüsüdür.

4.10.1.2. D1. Naive Bayes Sonuçları

Bağımlı değişken olan bayi bölgesi üzerinde etkisi olan 11 özneliğin etkisi olduğu tespit edilmiş olup ve Naive Bayes algoritmasından elde edilen sonuçlarda, 6452 veri doğru 1676 veri ise yanlış sınıflandırılmıştır. Karmaşıklık matrisinden Tablo 6 elde edilmiştir. Algoritmaya ait kappa katsayısı 0.7590 olarak elde edilmiş ve kappa katsayı değer aralıklarına göre iyi düzeyde uyum içerisinde yer almaktadır. Naive Bayes karmaşıklık matrisine göre verilen sonuçlar incelendiğinde en düşük doğruluk değerlerine sahip olan Bayi 1, Bayi 2, Bayi 3, Bayi 4, Bayi 6 ve Bayi 5 takip etmiştir. En yüksek doğruluk değerini Bayi 7 vermiştir.

Naive Bayes sınıflandırma algoritması eğitim olarak %66 ve test olarak da %33 ayrılarak 79.3799 % doğrulukla tahmin edilmiştir.

Tablo-6: Naive Bayes Algoritması Karmaşıklık Matrisi

		Tahmini Sınıf						
		Bayi 1	Bayi 2	Bayi 3	Bayi 4	Bayi 5	Bayi 6	Bayi 7
Gerçek Sınıf	Bayi 1	848	38	35	23	50	39	30
	Bayi 2	32	858	28	34	37	40	42
	Bayi 3	35	35	871	35	43	33	53
	Bayi 4	36	25	25	858	45	41	38
	Bayi 5	31	47	38	34	1012	39	47
	Bayi 6	28	30	38	26	34	903	75
	Bayi 7	45	48	44	47	51	102	1102

Tablo-7: Naive Bayes Algoritması Karmaşıklık Matrisi

Değerlendirme metriği	Metrik Değeri Yüzde (%)
Ortalama Doğruluk	79,4
Ortalama Hata Oranı	3,5
Ortalama Hatırlama	79,4
Ortalama Hassasiyet	79,4
Ortalama F1-Skoru	79,4

Naive Bayes algoritması ile gerçekleştirilen sınıflandırma işlemi sonucunda elde edilen farklı değerlendirme metrik değerleri Tablo-7' de verilmiştir. Değerlendirme metrik sonuçlarında ortalama doğruluk oranı 79,4% olarak bulunmakta ve doğru sınıflandırılan verilerin toplama bölümü sonucunda elde edilen veridir. Ortalama Hata oranı 3,4% olarak bulunmuştur ve yanlış sınıflandırılan verilerin toplama bölümü sonucu elde edilen verilerdir. Ortalama hatırlama oranı 79,4% olarak bulunmuş ve pozitif durumların ne kadar başarılı olduğu tahmin edilmiştir. Ortalama hassasiyet oranı 79,4% oranı olarak bulunmuş ve pozitif olarak tahmin edilen sınıflandırmanın başarısını göstermektedir. Ortalama F1-Skor oranı ortalama hatırlama ve ortalama hassasiyet oranlarının harmonik ortalaması alınarak 79,4% olarak bulunmuş ve sınıflandırmanın ne kadar iyi performans gösterdiğinin ölçüsüdür.

4.10.1.3. D1. k-en Yakın Komşu Algoritması Sonuçları

Bağımlı değişken olan bayi bölgesi üzerinde etkisi olan 11 özneliğin etkisi olduğu tespit edilmiş olup k-en Yakın Komşu algoritması algoritmasından elde edilen sonuçlarda, 5997 veri doğru 2131 veri ise yanlış sınıflandırılmıştır. KNN daha iyi sonuç vermesi için değeri 10 olarak verilmiştir. Karmaşıklık matrisinden Tablo-8 elde edilmiştir. Algoritmaya ait kappa katsayısı 0.6936 olarak elde edilmiş ve kappa katsayı değer aralıklarına göre iyi düzeyde uyum içerisinde yer almaktadır. k-en Yakın Komşu Algoritması karmaşıklık matrisine göre verilen sonuçlar incelendiğinde en düşük doğruluk değerlerine sahip olan Bayi 2, Bayi 1, Bayi 3, Bayi 4, Bayi 6 ve Bayi 5 takip etmiştir. En yüksek doğruluk değerini Bayi 7 vermiştir.

k-en Yakın Komşu sınıflandırma algoritması eğitim olarak %66 ve test olarak da %33 ayrılarak 73.782% doğrulukla tahmin edilmiştir.

Tablo-8: k-en Yakın Komşu Algoritması Karmaşıklık Matrisi

		Tahmini Sınıf						
		Bayi 1	Bayi 2	Bayi 3	Bayi 4	Bayi 5	Bayi 6	Bayi 7
Gerçek Sınıf	Bayi 1	805	44	35	34	67	39	39
	Bayi 2	59	792	33	36	43	49	59
	Bayi 3	59	49	803	38	52	42	62
	Bayi 4	53	43	36	786	53	51	46
	Bayi 5	58	63	53	38	947	38	51
	Bayi 6	45	42	50	35	48	839	75
	Bayi 7	63	63	54	54	72	108	1025

Tablo 9: k-en Yakın Komşu Algoritması Performans Sonuçları

Değerlendirme metriği	Metrik Değeri Yüzde (%)
Ortalama Doğruluk	73,8
Ortalama Hata Oranı	4,4
Ortalama Hatırlama	73,8
Ortalama Hassasiyet	73,9
Ortalama F1-Skoru	73,8

k-en Yakın Komşu algoritması ile gerçekleştirilen sınıflandırma işlemi sonucunda elde edilen farklı değerlendirme metrik değerleri Tablo-9 'da verilmiştir. Değerlendirme metrik sonuçları, ortalama doğruluk oranı 73,8% olarak bulunmakta ve doğru sınıflandırılan verilerin toplama bölümü sonucunda elde edilen veridir. Ortalama Hata oranı 4,4% olarak bulunmuştur ve yanlış sınıflandırılan verilerin toplama bölümü sonucu elde edilen verilerdir. Ortalama hatırlama oranı 73,8% olarak bulunmuş ve pozitif durumların ne kadar başarılı olduğu tahmin edilmiştir. Ortalama hassasiyet oranı 73,9% oranı olarak bulunmuş ve pozitif olarak tahmin edilen sınıflandırmanın başarısını göstermektedir. Ortalama F1-Skor oranı ortalama hatırlama

ve ortalama hassasiyet oranlarının harmonik ortalaması alınarak 73,8% olarak bulunmuş ve sınıflandırmanın ne kadar iyi performans gösterdiğinin ölçüsüdür.

4.10.1.4. D1. LWL (Locally Weighted Learning- Yerel Ağırlıklı Öğrenme) Algoritması

Sonuçları

Bağımlı değişken olan bayi bölgesi üzerinde etkisi olan 11 özneliğin etkisi olduğu tespit edilmiş olup LWL algoritması algoritmasından elde edilen sonuçlarda, 5808 veri doğru 2320 veri ise yanlış sınıflandırılmıştır. Karmaşıklık matrisinden Tablo-10 elde edilmiştir. LWL daha iyi sonuç vermesi için özelliklerinde Bayes Net algoritması seçilmiş ve KNN değeri 10 olarak girilmiştir. Algoritmaya ait kappa katsayısı 0.6663 olarak elde edilmiş ve kappa katsayı değer aralıklarına göre iyi düzeyde uyum içerisinde yer almaktadır. LWL Algoritması karmaşıklık matrisine göre verilen sonuçlar incelendiğinde en düşük doğruluk değerlerine sahip olan Bayi 1, Bayi 2, Bayi 3, Bayi 4, Bayi 6 ve Bayi 5 takip etmiştir. En yüksek doğruluk değerini Bayi 7 vermiştir.

LWL sınıflandırma algoritması eğitim olarak %66 ve test olarak da %33 ayrılarak 71.4567 % doğrulukla tahmin edilmiştir.

Tablo-10:LWL Algoritması Karmaşıklık Matrisi

		Tahmini Sınıf						
		Bayi 1	Bayi 2	Bayi 3	Bayi 4	Bayi 5	Bayi 6	Bayi 7
Gerçek Sınıf	Bayi 1	764	48	43	41	69	56	42
	Bayi 2	45	751	39	47	60	58	71
	Bayi 3	42	43	777	49	61	59	74
	Bayi 4	41	42	34	781	58	53	59
	Bayi 5	46	57	62	50	916	55	62
	Bayi 6	36	50	52	41	54	809	92
	Bayi 7	63	65	61	57	79	104	1010

Tablo-11:LWL Algoritması Performans Sonuçları

Değerlendirme metriği	Metrik Değeri Yüzde (%)
Ortalama Doğruluk	71,5
Ortalama Hata Oranı	4,8
Ortalama Hatırlama	71,5
Ortalama Hassasiyet	71,5
Ortalama F1-Skoru	71,5

LWL algoritması ile gerçekleştirilen sınıflandırma işlemi sonucunda elde edilen farklı değerlendirme metrik değerleri Tablo-11 'de verilmiştir. Değerlendirme metrik sonuçları, ortalama doğruluk oranı 71,5% olarak bulunmakta ve doğru sınıflandırılan verilerin toplama bölümü sonucunda elde edilen veridir. Ortalama Hata oranı 4,8% olarak bulunmuştur ve yanlış sınıflandırılan verilerin toplama bölümü sonucu elde edilen verilerdir. Ortalama hatırlama oranı 71,5% olarak bulunmuş ve pozitif durumların ne kadar başarılı olduğu tahmin edilmiştir. Ortalama hassasiyet oranı 71,5% oranı olarak bulunmuş ve pozitif olarak tahmin edilen sınıflandırmanın başarısını göstermektedir. Ortalama F1-Skor oranı ortalama hatırlama ve ortalama hassasiyet oranlarının harmonik ortalaması alınarak 71,5% olarak bulunmuş ve sınıflandırmanın ne kadar iyi performans gösterdiğinin ölçüsüdür.

4.10.1.5. D1. Adaboost M1 Sonuçları

Bağımlı değişken olan bayi bölgesi üzerinde etkisi olan 11 özneliğin etkisi olduğu tespit edilmiş olup Adaboost M1 algoritmasından elde edilen sonuçlarda, 6460 veri doğru 1668 veri ise yanlış sınıflandırılmıştır. Karmaşıklık matrisinden Tablo-12 elde edilmiştir. Adaboost M1 daha iyi sonuç vermesi için RepTree algoritması seçilmiştir. Algoritmaya ait kappa katsayısı 0.7603 olarak elde edilmiş ve kappa katsayı değer aralıklarına göre iyi düzeyde uyum içerisinde yer almaktadır. Adaboost M1 Algoritması karmaşıklık matrisine göre verilen sonuçlar incelendiğinde en düşük doğruluk değerlerine sahip olan Bayi 1, Bayi 2, Bayi 3, Bayi 4, Bayi 6 ve Bayi 5 takip etmiştir. En yüksek doğruluk değerini Bayi 7 vermiştir.

Adaboost M1 sınıflandırma algoritması eğitim olarak %66 ve test olarak da %33 ayrılarak 79.4783 % doğrulukla tahmin edilmiştir.

Tablo-12: Adaboost M1 Algoritması Karmaşıklık Matrisi

		Tahmini Sınıf						
		Bayi 1	Bayi 2	Bayi 3	Bayi 4	Bayi 5	Bayi 6	Bayi 7
Gerçek Sınıf	Bayi 1	849	38	35	23	50	40	28
	Bayi 2	32	858	29	34	37	42	39
	Bayi 3	35	31	875	35	42	38	49
	Bayi 4	36	25	25	858	45	45	34
	Bayi 5	31	47	38	35	1012	45	40
	Bayi 6	28	27	38	26	34	940	41
	Bayi 7	45	47	44	47	51	137	1068

Tablo-13: Adaboost M1 Algoritması Performans Sonuçları

Değerlendirme metriği	Metrik Değeri Yüzde (%)
Ortalama Doğruluk	79,5
Ortalama Hata Oranı	3,4
Ortalama Hatırlama	79,5
Ortalama Hassasiyet	79,7
Ortalama F1-Skoru	79,5

Adaboost M1 algoritması ile gerçekleştirilen sınıflandırma işlemi sonucunda elde edilen farklı değerlendirme metrik değerleri Tablo-13 'te verilmiştir. Değerlendirme metrik sonuçları, ortalama doğruluk oranı 79,5% olarak bulunmakta ve doğru sınıflandırılan verilerin toplama bölümü sonucunda elde edilen veridir. Ortalama Hata oranı 5,4% olarak bulunmuştur ve yanlış sınıflandırılan verilerin toplama bölümü sonucu elde edilen verilerdir. Ortalama hatırlama oranı 79,5% olarak bulunmuş ve pozitif durumların ne kadar başarılı olduğu tahmin edilmiştir. Ortalama hassasiyet oranı 79,7% oranı olarak bulunmuş ve pozitif olarak tahmin edilen sınıflandırmanın başarısını göstermektedir. Ortalama F1-Skor oranı ortalama hatırlama ve

ortalama hassasiyet oranlarının harmonik ortalaması alınarak 79,5% olarak bulunmuş ve sınıflandırmanın ne kadar iyi performans gösterdiğinin ölçüsüdür.

4.10.1.6. D1. Bagging Sonuçları

Bağımlı değişken olan bayi bölgesi üzerinde etkisi olan 11 özneliğin etkisi olduğu tespit edilmiş olup Bagging algoritmasından elde edilen sonuçlarda, 6444 veri doğru 1684 veri ise yanlış sınıflandırılmıştır. Karmaşıklık matrisinden Tablo-14 elde edilmiştir. Bagging daha iyi sonuç vermesi için Naive Bayes algoritması seçilmiştir. Algoritmaya ait kappa katsayısı 0.7607 olarak elde edilmiş ve kappa katsayı değer aralıklarına göre orta düzeyde uyum içerisinde yer almaktadır. Bagging Algoritması karmaşıklık matrisine göre verilen sonuçlar incelendiğinde en düşük doğruluk değerlerine sahip olan Bayi 1, Bayi 2, Bayi 3, Bayi 4, Bayi 6 ve Bayi 5 takip etmiştir. En yüksek doğruluk değerini Bayi 7 vermiştir.

Bagging sınıflandırma algoritması eğitim olarak %66 ve test olarak da %33 ayrılarak 79.2815% doğrulukla tahmin edilmiştir.

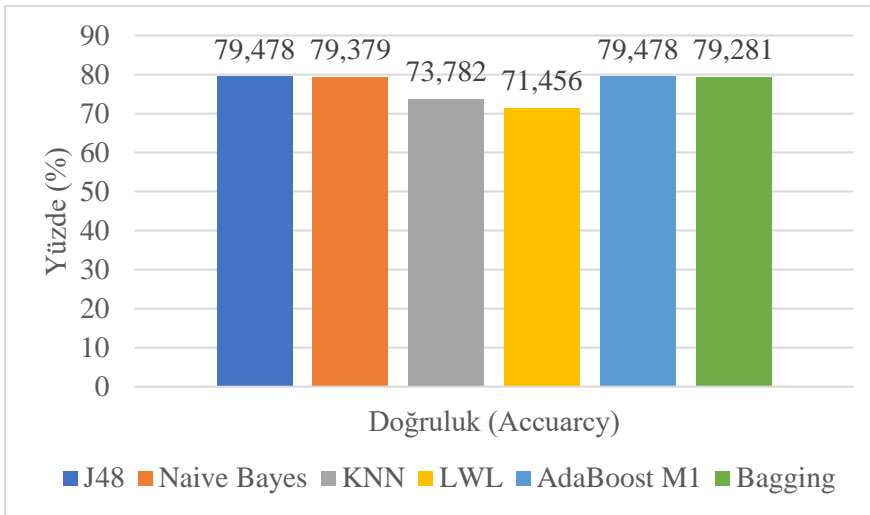
Tablo-14: Bagging Algoritması Karmaşıklık Matrisi

		Tahmini Sınıf						
		Bayi 1	Bayi 2	Bayi 3	Bayi 4	Bayi 5	Bayi 6	Bayi 7
Gerçek Sınıf	Bayi 1	847	38	35	23	50	39	31
	Bayi 2	32	857	28	34	38	40	42
	Bayi 3	35	35	872	35	42	32	54
	Bayi 4	36	25	25	858	45	39	40
	Bayi 5	31	48	38	34	1011	37	49
	Bayi 6	28	33	38	26	34	893	82
	Bayi 7	45	50	44	48	51	95	1106

Tablo-15: Bagging Algoritması Performans Sonuçları

Değerlendirme metriği	Metrik Değeri Yüzde (%)
Ortalama Doğruluk	79,3
Ortalama Hata Oranı	3,5
Ortalama Hatırlama	79,3
Ortalama Hassasiyet	79,3
Ortalama F1-Skoru	79,3

Bagging algoritması ile gerçekleştirilen sınıflandırma işlemi sonucunda elde edilen farklı değerlendirme metrik değerleri Tablo-15 'te verilmiştir. Değerlendirme metrik sonuçları, ortalama doğruluk oranı 79,3% olarak bulunmakta ve doğru sınıflandırılan verilerin toplama bölümü sonucunda elde edilen veridir. Ortalama Hata oranı 3,5% olarak bulunmuştur ve yanlış sınıflandırılan verilerin toplama bölümü sonucu elde edilen verilerdir. Ortalama hatırlama oranı 79,3% olarak bulunmuş ve pozitif durumların ne kadar başarılı olduğu tahmin edilmiştir. Ortalama hassasiyet oranı 79,3% oranı olarak bulunmuş ve pozitif olarak tahmin edilen sınıflandırmanın başarısını göstermektedir. Ortalama F1-Skor oranı ortalama hatırlama ve ortalama hassasiyet oranlarının harmonik ortalaması alınarak 79,3% olarak bulunmuş ve sınıflandırmanın ne kadar iyi performans gösterdiğinin ölçüsüdür.

Şekil-22: D1 Veri Seti Sınıflandırma Algoritmaları Başarı Oranı Sonuçları

Bu çalışmada bağımlı değişken olan bayi bölgesi için uygulanan sınıflandırma algoritmalarından elde edilen sonuçlar karşılaştırılarak en yüksek doğruluk oranını J48 ve AdaBoost M1 vermiştir. Bu algoritmalar en yakın sonucu veren Naive Bayes ve Bagging olmuştur. En düşük doğruluk oranlarını LWL ve KNN algoritmaları olmuştur.

Bu çalışmada karmaşıklık matrisi değerlendirmesine göre sınıflandırma algoritmalarının verdiği sonuçlar doğrultusunda en çok tercih edilen bayi bölgesinin yedinci bayi olduğu görülmektedir.

4.10.1.7. D2 Veri Seti Model Sonuçları

Bu bölümde deneyde kullanılan modellerin performansı ölçüm metrikler açısından değerlendirilmiştir. Amaç, müşterilerin yıllık gelirine göre hangi marka, model, motor, vites, gövde stili ve renk seçerek otomobil alıp almayacağını belirleyecek olan en iyi sınıflandırıcıyı bulmaktır.

Tablo-16: D2 Modeli Matris ve Performans Metrikleri

Algoritmalar	Matris				Ortalama Doğruluk %	Ortalama Hata Oranı %	Ortalama Hatırlama %	Ortalama Hassasiyet %	Ortalama F1-Skoru %
	a	b	c	d					
Desicion Tree (Karar Ağaçları)	3348	0	0	0	100	0,0	100	100	100
	0	2251	0	0					
	0	0	1696	0					
	0	1	0	832					
Naive Bayes	3215	0	133	0	97,0	1,1	97,2	97,0	97,1
	9	2204	8	0					
	0	34	1655	7					
	0	49	0	784					
k-en Yakın Komşu	3092	26	224	6	86,7	5,4	86,9	86,7	86,7
	206	1958	84	3					
	32	198	1408	58					
	46	221	68	498					
LWL (Locally Weighted Learning- Yerel Ağırlıklı Öğrenme)	3094	35	213	6	83,6	7,2	83,6	83,6	83,3
	266	1881	90	14					
	114	225	1302	55					
	47	212	58	516					
Adaboost M1	3347	0	1	0	99,9	0,1	99,9	99,9	99,9
	0	2251	0	0					
	0	3	1693	0					
	0	2	0	831					

Bagging	3221	0	127	0	97,1	1,1	97,2	97,1	97,1
	10	2230	11	0					
	0	37	1656	3					
	0	48	0	785					

a= 10080-639000 b= 640000-1016000 c= 1017000-1675000 d= 1679000-11200000

Bu çalışmada bağımlı değişken olan "Yıllık Gelir Aralığı" WEKA programı ile modellenerek daha iyi tahmin etmek üzere kurulmuş ve dolayısıyla bu kriterde algoritmaların performans başarısını yüksek performans elde etmeye odaklanmıştır.

Tablo16'da bağımlı değişken olan yıllık gelir aralığı üzerinde etkisi olan özniteliklerin etkisi olduğu tespit edilmiş olup ve Decision Tree (J48) algoritmasından elde edilen sonuçlar, 8127 veri doğru olarak sınıflandırılmış fakat 1 veri ise yanlış sınıflandırılmıştır. Karmaşıklık matrisinden Tablo-16 elde edilmiştir. Algoritmaya ait kappa katsayısı 0.9998 olarak elde edilmiş ve kappa katsayı değer aralıklarına göre çok iyi düzeyde uyum içerisindedir. En yüksek doğruluk değerini yıllık gelir aralığı özelliklerinden a (10080-639000) vermiş ve en düşük doğruluk değerini d (1679000-11200000) özelliği vermiştir. Decision Tree (J48) sınıflandırma algoritması eğitim olarak %66 ve test olarak da %33 ayrılarak 99.9877 % doğrulukla tahmin edilmiştir.

Decision Tree (J48) algoritması ile gerçekleştirilen sınıflandırma işlemi sonucunda elde edilen farklı değerlendirme metrik değerleri Tablo-16 'de verilmiştir. Değerlendirme metrik sonuçları, ortalama doğruluk oranı 100% olarak bulunmakta ve doğru sınıflandırılan verilerin toplama bölümü sonucunda elde edilen veridir. Ortalama Hata oranı 0,0% olarak bulunmuştur ve yanlış sınıflandırılan verilerin toplama bölümü sonucu elde edilen verilerdir. Ortalama hatırlama oranı 100% olarak bulunmuş ve pozitif durumların ne kadar başarılı olduğu tahmin edilmiştir. Ortalama hassasiyet oranı 100% oranı olarak bulunmuş ve pozitif olarak tahmin edilen sınıflandırmanın başarısını göstermektedir. Ortalama F1-Skor oranı ortalama hatırlama ve ortalama hassasiyet oranlarının harmonik ortalaması alınarak 100% olarak bulunmuş ve sınıflandırmanın ne kadar iyi performans gösterdiğinin ölçüsüdür.

Bağımlı değişken olan yıllık gelir aralığı üzerinde etkisi olan özniteliklerin etkisi olduğu tespit edilmiş olup ve Naive Bayes algoritmasından elde edilen sonuçlarda, 7888 veri doğru 240 veri ise yanlış sınıflandırılmıştır. Karmaşıklık matrisinden Tablo-16'da elde edilmiştir. Algoritmaya ait kappa katsayısı 0.9579 olarak elde edilmiş ve kappa katsayı değer aralıklarına

göre iyi düzeyde uyum içerisinde yer almaktadır. En yüksek doğruluk değerini yıllık gelir aralığı gruplandırmasında a (10080-639000) özelliği vermiş ve en düşük doğruluk değerini d (1679000-11200000) özelliği vermiştir. Naive Bayes sınıflandırma algoritması eğitim olarak %66 ve test olarak da %33 ayrılarak 97.0472 % doğrulukla tahmin edilmiştir.

Naive Bayes algoritması ile gerçekleştirilen sınıflandırma işlemi sonucunda elde edilen farklı değerlendirme metrik değerleri Tablo-16 'da verilmiştir. Değerlendirme metrik sonuçları, ortalama doğruluk oran 97,0% olarak bulunmakta ve doğru sınıflandırılan verilerin toplama bölümü sonucunda elde edilen veridir. Ortalama Hata oranı 1,1% olarak bulunmuştur ve yanlış sınıflandırılan verilerin toplama bölümü sonucu elde edilen verilerdir. Ortalama hatırlama oranı 97,2% olarak bulunmuş ve pozitif durumların ne kadar başarılı olduğu tahmin edilmiştir. Ortalama hassasiyet oranı 97,0% oranı olarak bulunmuş ve pozitif olarak tahmin edilen sınıflandırmanın başarısını göstermektedir. Ortalama F1-Skor oranı ortalama hatırlama ve ortalama hassasiyet oranlarının harmonik ortalaması alınarak 97,1% olarak bulunmuş ve sınıflandırmanın ne kadar iyi performans gösterdiğinin ölçüsüdür.

Tablo 16'yı değerlendirdiğimizde, bağımlı değişken olan yıllık gelir aralığı üzerinde etkisi olan öznitelikler olduğu tespit edilmiş olup k-en Yakın Komşu algoritması algoritmasından elde edilen sonuçlarda, 7049 veri doğru 1079 veri ise yanlış sınıflandırılmıştır. Karmaşıklık matrisinden Tablo-16 elde edilmiştir. Algoritmaya ait kappa katsayısı 0.8093 olarak elde edilmiş ve kappa katsayı değer aralıklarına göre çok iyi düzeyde uyum içerisinde yer almaktadır. k-en Yakın Komşu Algoritması karmaşıklık matrisine göre verilen sonuçlar incelendiğinde en yüksek doğruluk değerini yıllık gelir aralığı gruplandırmasında a (10080-639000) özelliği vermiş ve en düşük doğruluk değerini d (1679000-11200000) özelliği vermiştir. k-en Yakın Komşu sınıflandırma algoritması eğitim olarak %66 ve test olarak da %33 ayrılarak 86.7249 % doğrulukla tahmin edilmiştir.

k-en Yakın Komşu algoritması ile gerçekleştirilen sınıflandırma işlemi sonucunda elde edilen farklı değerlendirme metrik değerleri Tablo-16 'da verilmiştir. Değerlendirme metrik sonuçları, ortalama doğruluk oran 86,7% olarak bulunmakta ve doğru sınıflandırılan verilerin toplama bölümü sonucunda elde edilen veridir. Ortalama Hata oranı 5,4% olarak bulunmuştur ve yanlış sınıflandırılan verilerin toplama bölümü sonucu elde edilen verilerdir. Ortalama hatırlama oranı 86,9% olarak bulunmuş ve pozitif durumların ne kadar başarılı olduğu tahmin edilmiştir. Ortalama hassasiyet oranı 86,7 % oranı olarak bulunmuş ve pozitif olarak tahmin edilen sınıflandırmanın başarısını göstermektedir. Ortalama F1-Skor oranı ortalama hatırlama

ve ortalama hassasiyet oranlarının harmonik ortalaması alınarak 86,7 % olarak bulunmuş ve sınıflandırmanın ne kadar iyi performans gösterdiğinin ölçüsüdür.

Tablo 16'yı değerlendirdiğimizde, bağımlı değişken olan yıllık gelir aralığı üzerinde etkisi olan öznitelikler tespit edilmiş olup LWL algoritması algoritmasından elde edilen sonuçlarda, 6793 veri doğru 1335 veri ise yanlış sınıflandırılmıştır. Karmaşıklık matrisinden Tablo-16 elde edilmiştir. LWL daha iyi sonuç vermesi için özelliklerinde Bayes Net algoritması seçilmiş ve KNN değeri 10 olarak girilmiştir. Algoritmaya ait kappa katsayısı 0.7623 olarak elde edilmiş ve kappa katsayı değer aralıklarına göre iyi düzeyde uyum içerisinde yer almaktadır. LWL algoritması karmaşıklık matrisine göre verilen sonuçlar incelendiğinde en yüksek doğruluk değerini yıllık gelir aralığı gruplandırmasında a (10080-639000) özelliği vermiş ve en düşük doğruluk değerini d (1679000-11200000) özelliği vermiştir. LWL sınıflandırma algoritması eğitim olarak %66 ve test olarak da %33 ayrılarak 83.5753% doğrulukla tahmin edilmiştir.

LWL algoritması ile gerçekleştirilen sınıflandırma işlemi sonucunda elde edilen farklı değerlendirme metrik değerleri Tablo-16 'da verilmiştir. Değerlendirme metrik sonuçları, ortalama doğruluk oran 83,6% olarak bulunmakta ve doğru sınıflandırılan verilerin toplama bölümü sonucunda elde edilen veridir. Ortalama Hata oranı 7,2% olarak bulunmuştur ve yanlış sınıflandırılan verilerin toplama bölümü sonucu elde edilen verilerdir. Ortalama hatırlama oranı 83,6% olarak bulunmuş ve pozitif durumların ne kadar başarılı olduğu tahmin edilmiştir. Ortalama hassasiyet oranı 86,6 % oranı olarak bulunmuş ve pozitif olarak tahmin edilen sınıflandırmanın başarısını göstermektedir. Ortalama F1-Skor oranı ortalama hatırlama ve ortalama hassasiyet oranlarının harmonik ortalaması alınarak 83,3 % olarak bulunmuş ve sınıflandırmanın ne kadar iyi performans gösterdiğinin ölçüsüdür.

Tablo 16'yı değerlendirdiğimizde, bağımlı değişken olan yıllık gelir aralığı üzerinde etkisi olan öznitelikler olduğu tespit edilmiş olup AdaBoost M1 algoritması algoritmasından elde edilen sonuçlarda, 8122 veri doğru 6 veri ise yanlış sınıflandırılmıştır. Karmaşıklık matrisinden Tablo-16 elde edilmiştir. Adaboost M1 daha iyi sonuç vermesi için RepTree algoritması seçilmiştir. Algoritmaya ait kappa katsayısı 0.9989 olarak elde edilmiş ve kappa katsayı değer aralıklarına göre çok iyi düzeyde uyum içerisinde yer almaktadır. AdaBoost M1 algoritması karmaşıklık matrisine göre verilen sonuçlar incelendiğinde en yüksek doğruluk değerini yıllık gelir aralığı gruplandırmasında a (10080-639000) özelliği vermiş ve en düşük doğruluk değerini d (1679000-11200000) özelliği vermiştir. k-en Yakın Komşu sınıflandırma

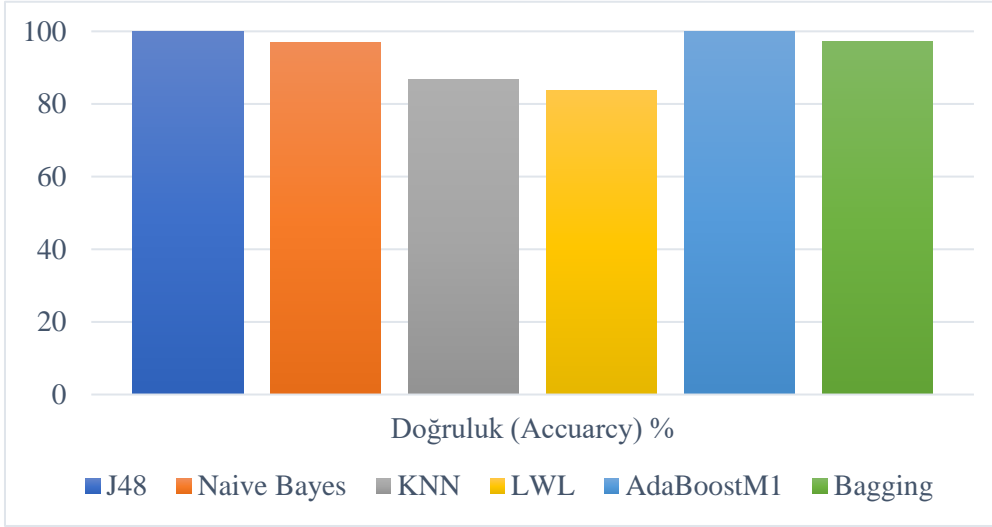
algoritması eğitim olarak %66 ve test olarak da %33 ayrılarak 99.9262% doğrulukla tahmin edilmiştir.

AdaBoost M1 algoritması ile gerçekleştirilen sınıflandırma işlemi sonucunda elde edilen farklı değerlendirme metrik değerleri Tablo-16 'da verilmiştir. Değerlendirme metrik sonuçları, ortalama doğruluk oran 99,9 % olarak bulunmakta ve doğru sınıflandırılan verilerin toplama bölümü sonucunda elde edilen veridir. Ortalama Hata oranı 0,1% olarak bulunmuştur ve yanlış sınıflandırılan verilerin toplama bölümü sonucu elde edilen verilerdir. Ortalama hatırlama oranı 99,9% olarak bulunmuş ve pozitif durumların ne kadar başarılı olduğu tahmin edilmiştir. Ortalama hassasiyet oranı 99,9% oranı olarak bulunmuş ve pozitif olarak tahmin edilen sınıflandırmanın başarısını göstermektedir. Ortalama F1-Skor oranı ortalama hatırlama ve ortalama hassasiyet oranlarının harmonik ortalaması alınarak 99,9% olarak bulunmuş ve sınıflandırmanın ne kadar iyi performans gösterdiğinin ölçüsüdür.

Tablo 16'yı değerlendirdiğimizde, bağımlı değişken olan yıllık gelir aralığı üzerinde etkisi olan öznitelikler olduğu tespit edilmiş olup Bagging algoritması algoritmasından elde edilen sonuçlarda, 7892 veri doğru 236 veri ise yanlış sınıflandırılmıştır. Karmaşıklık matrisinden Tablo-16 elde edilmiştir. Bagging daha iyi sonuç vermesi için Naive Bayes algoritması seçilmiştir. Algoritmaya ait kappa katsayısı 0.9586 olarak elde edilmiş ve kappa katsayı değer aralıklarına göre çok iyi düzeyde uyum içerisinde yer almaktadır. Bagging karmaşıklık matrisine göre verilen sonuçlar incelendiğinde en yüksek doğruluk değerini yıllık gelir aralığı gruplandırmasında a (10080-639000) özelliği vermiş ve en düşük doğruluk değerini d (1679000-11200000) özelliği vermiştir. k-en Yakın Komşu sınıflandırma algoritması eğitim olarak %66 ve test olarak da %33 ayrılarak 97.0965 % doğrulukla tahmin edilmiştir.

Bagging algoritması ile gerçekleştirilen sınıflandırma işlemi sonucunda elde edilen farklı değerlendirme metrik değerleri Tablo-16 'da verilmiştir. Değerlendirme metrik sonuçları, ortalama doğruluk oran 97,1% olarak bulunmakta ve doğru sınıflandırılan verilerin toplama bölümü sonucunda elde edilen veridir. Ortalama Hata oranı 1,1% olarak bulunmuştur ve yanlış sınıflandırılan verilerin toplama bölümü sonucu elde edilen verilerdir. Ortalama hatırlama oranı 97,2% olarak bulunmuş ve pozitif durumların ne kadar başarılı olduğu tahmin edilmiştir. Ortalama hassasiyet oranı 97,1% oranı olarak bulunmuş ve pozitif olarak tahmin edilen sınıflandırmanın başarısını göstermektedir. Ortalama F1-Skor oranı ortalama hatırlama ve ortalama hassasiyet oranlarının harmonik ortalaması alınarak 97,1% olarak bulunmuş ve sınıflandırmanın ne kadar iyi performans gösterdiğinin ölçüsüdür.

Şekil-23: D2 Veri Seti İçin Sınıflandırma Algoritmaları Başarı Oranı Sonuçları



Bu çalışmada bağımlı değişken olan yıllık gelir aralığı için uygulanan sınıflandırma algoritmalarından elde edilen sonuçlar karşılaştırılarak en yüksek doğruluk oranını J48 algoritması vermiştir. Bu algoritmalara en yakın sonucu veren AdaBoostM1, Bagging ve Naive Bayes olmuştur. En düşük doğruluk oranlarını LWL ve KNN algoritmaları olmuştur.

Bu çalışmada karmaşıklık matrisi değerlendirmesine göre sınıflandırma algoritmalarının verdiği sonuçlar doğrultusunda yıllık gelir aralık gruplandırmasında en yüksek doğruluk değerini yıllık gelir aralığı gruplandırmasında a (10080-639000) özelliği vermiş ve en düşük doğruluk değerini d (1679000-11200000) özelliği vermiştir. Bu durumda en çok kar ettiği yıllık gelir aralığına dair araba fiyatlarının belirlenmesi ve otomobillerin özelliklerine göre müşterinin tercihlerini tahmin edilmiştir.

Tartışma ve Sonuç

Literatür taramasında yapılan bu çalışmaya dair makaleler incelendiğinde hangi sınıflandırma algoritmalarının kullanıldığının karşılaştırılması yapılmıştır. Aşağıdaki tabloda başarı performans oranları gösterilmektedir.

Tablo-17: Literatürde Kullanılan Algoritmaların Başarı Performansları

Yazar	Algoritma	Başarı Performansları
Panda, 2022	Karar Ağaçları (DT)	% 97,4
Wah, vd., 2011	DT	% 91,17
Mou, vd., 2021	Naive Bayes	% 41
	KNN	% 73
Ahaggach, vd., 2023	Karar Ağaçları (DT)	% 99
	KNN	% 97,1
Park, 2021	DT	% 83,9
	Naive Bayes	% 83,9
	KNN	% 89,2

J48 (Karar ağaçları) algoritma performansı: Literatür de Panda (2022) tarafından yapılan çalışmada en iyi doğruluk oranını J48 (Karar ağaçları) sınıflandırıcısı tarafından verilen %97,4 elde edilmiş. Wah, vd., (2011) taraflarından yapılan çalışmada en iyi doğruluk oranını J48 (Karar ağaçları) %91,17 olarak elde edilmiş. Ahaggach, vd., (2023) taraflarından yapılan çalışmada %99 doğruluk oranı elde edilmiş ve Park (2021) tarafından yapılan çalışma da ise %83,9 doğruluk oranı elde edilmiş. Çalışmada elde edilen %79,4783 doğruluk oranı ile literatürdeki çalışmalar arasında yakın bir performans gösterdiği gözlemlenmiştir.

KNN (K-en yakın komşu) algoritma performansı: Literatür de Mou, vd., (2021) taraflarından yapılan çalışmada KNN sınıflandırma algoritması %73 başarı oranı göstermiştir. Ahaggach, vd., (2023) taraflarından yapılan çalışmada %97,1 doğruluk oranı elde edilmiş ve Park (2021) tarafından yapılan çalışma da ise %89,2 doğruluk oranı elde edilmiştir. Çalışmada elde edilen %73,782 doğruluk oranı ile literatürdeki bir çalışmadaki sonuçla benzerlik gösterdiği gözlemlenmiş fakat diğer çalışmalarla uyumlu olmadığı gözlemlenmiştir.

Naive Bayes algoritma başarı performansı: Mou, vd., (2021) taraflarından yapılan çalışmada Naive Bayes sınıflandırma algoritması % 41 başarı oranı göstermiş ve Park (2021)

tarafından yapılan çalışma da ise %83,9 doğruluk oranı elde edilmiş. Bu çalışmada, naive bayes algoritması %79,379 doğruluk oranı elde edilmiştir. Bu, Naive Bayes'in literatürdeki bir çalışmadaki sonuçla benzerlik gösterdiği gözlemlenmiş fakat diğer çalışmada uyumlu olmadığı gözlemlenmiştir.

Literatürde genellikle satın alınmak istenilen otomobillerinin hangi özelliklere sahip olduklarına dair sınıflandırma algoritmaları uygulanmıştır. Bu çalışmada ise müşterilerin daha çok hangi bayi bölgesinden ve yıllık gelir aralığına göre otomobil satın alınıp alınmadığına dair bilgiler yer almaktadır. Bu sayede tercih edilen bayi bölgesindeki otomobillerin özelliklerine göre ve yıllık gelire göre tercih edilen özellikler ile satışların tedarik zincirindeki pazar stratejilerinin geliştirilmesi incelenmiştir.

Literatüre baktığımızda farklı sınıflandırma algoritmaları kullanılarak başarı oranları hesaplanmış ve en yüksek performansı gösteren algoritmaların faydalı sonuçlar vermiştir. Bu sonuçlar ile otomobil alanındaki tedarik zinciri stratejileri geliştirilmiştir.

Özetle, yapılan bu çalışmada mevcut literatür taramasıyla tutarlı ve sınıflandırma algoritmalarından karar ağaçları ile benzer oranda yüksek doğruluk vermiş ve onu izleyen diğer bir sınıflandırma algoritması Naive Bayes olmuştur. KNN algoritması ise benzer oranlarda doğruluk oranı vermiştir. Veri setinde kullanılan algoritmaların performans düzeyleri literatürdeki benzer bulgularla uyumludur.

Tedarik zinciri müşterilerin istek ve ihtiyaçlarına uygun doğru ürünü, doğru zamanda ve doğru üretimle ulaştırmak için kullandığı bilişim sistemlerinden elde ettiği verileri inceleyerek daha hızlı kararlar alarak işletmelerin rekabet ortamında başarılı olmalarını sağlamaktadır. Bu durum işletmelerin daha fazla kar etmelerine ve sürekli değişen pazar ortamına ayak uydurmalarını etkin bir şekilde yaparak işletmelerin sürekliliğini sağlamaktadır. İşletmeler bu devamlılığı sürdürmek için verileri kullanarak daha iyi performans geliştirmektedirler. Bu nedenle veriler işletmeler açısından büyük bir öneme sahiptir.

Bu çalışmada WEKA programı kullanılarak veriler eğitilerek analizler yapılmıştır. Bu analizler sonucunda kullanılan sınıflandırma algoritmaları sayesinde verilerin doğruluk oranları hesaplanmıştır.

Bu çalışmada kullanılan algoritma performans sonuçları doğrultusunda tedarik zincirinde veri madenciliği kullanılarak müşterilerin hangi bayi bölgesinden sipariş ettiklerini ve yıllık

gelir aralığına göre satışların tahminlemeleri sınıflandırma algoritmaları ile yapılmıştır. Bu sayede bayi satış oranları ve yıllık gelirle ilgili bilgiler verilerek tedarik zincirine faydası sağlanmıştır.

Çalışmada verilerin daha iyi sonuç vermesi eğitim %66 ve test %33 olarak ayrılarak incelenmiştir. Sınıflandırma yapılabilmesi için J48, Bayes, KNN, LWL, Adaboost M1 ve Bagging algoritmaları kullanılmıştır. En iyi sonucu %79,4783 ile J48 ve onu izleyen yine %79,5 Adaboost M1, algoritmaları vermiştir. Sınıflandırma algoritmalarının değerlendirilebilmesi için karmaşıklık matrisi kullanılmıştır.

Çalışmada bağımlı değişken olan bayi bölgesini etkileyen 11 özneliğin analizi yapılmıştır. Amaç, müşterinin bayi bölgesine göre istediği otomobilin özelliklerine bakarak alışveriş etmesini sağlamaktır. Bu nedenle, Weka'da yapılan analizler sonucunda en çok tercih edilen bayi bölgesini tahmin edilmiştir. Çalışmada diğer bağımlı değişken olan yıllık gelir aralığını 7 öznelik etkilemiştir. Weka'da yapılan analizler sonucunda satış yapılan yıllık gelir aralığı gruplandırmasındaki müşterilerin otomobil alımları tahmin edilmiştir.

Ek olarak bu çalışma, müşterinin doğru zamanda ve doğru ürünü bulmasını kolaylaştırmaktadır. Ayrıca, bu çalışma bayi bölgelerinde yapılan otomobil satışlarında hangi özelliklerin seçildiğine dair bilgiler vermektedir. Bu bilgiler ile müşteriler seçtikleri bayilerde istedikleri özellikleri bulunduran ürünleri almaktadır. Bu sonuç ile müşterilerin memnuniyeti artırılması gibi olumlu sonuçlara yol açabileceği düşünülmektedir. Bu çalışmada yıllık gelir aralığına bakılarak bayilerin daha kolay satış fiyatlandırması oluşturabilmesine ve müşterilerin yıllık gelirine uygun otomobil özelliklerine göre üretim yapılması için faydalı bilgiler sağlayacağı düşünülmektedir.

Öneriler

Bu çalışmada Weka programı kullanılarak veri setinin doğru bir şekilde sınıflandırılması için birçok algoritma uygun bir şekilde seçilerek hesaplamak doğruluk oranlarının hesaplanması sağlanmıştır. Bu hesaplamalar sonucunda ne kadar doğru tahminleme yapıldığı ve ne kadar performans düzeylerinin başarılı olduğuna bakılmaktadır. Hesaplanan veriler doğrultusunda veri kümesinin algoritmalara ve değer verilmiş olunan çapraz doğrulama ile örtüşüp veya örtüşmediğinin sonuçları elde edilmiştir.

Yapılacak olan diğer sınıflandırma çalışmalarda, farklı algoritmalar kullanılarak elde edilen sonuçların gözlemlenerek daha verimli sonuçların ortaya çıkmasının sağlanması gerekmektedir. Böylelikle farklı algoritmaların doğru sonuçları elde edebilmesi için veri kümelerinin performans ölçümlerinde kullanılan göstergeler ortalama hatırlama, ortalama hassasiyet, ortalama doğruluk, ortalama hata oranı ve ortalama F1 skorlarındaki başarı düzeylerine bakılarak ne kadar etkilediklerine gözlemlemek gerekmektedir.

Kaynakça

- Ahaggach, H., Abrouk, L., Foufou, S., & Lebon, E. (2023). Predicting Car Sale Time with Data Analytics and Machine Learning. In IFIP advances in information and communication technology (pp. 399–409). https://doi.org/10.1007/978-3-031-25182-5_39.
- Akman, G. ve Alkan, A. (2006). Tedarik Zinciri Yönetiminde Bulanık AHP Yöntemi Kullanılarak Tedarikçilerin Performansının Ölçülmesi: Otomotiv Yan Sanayinde Bir Uygulama. İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, 9(1): 24.
- Akmut, Özdemir, R. Aktaş, B. Aykaç, M. M. Doğanay, T. Durukan, M. T. Müftüoğlu, Ö. Yüksel, (2003), Girişimciler İçin İşletme Yönetimi, Gazi, Ankara.
- (AdaBoostM1, 2022). <https://weka.sourceforge.io/doc.dev/weka/classifiers/meta/AdaBoostM1.html>
- Arslan, H. 2008. Sakarya Üniversitesi Web Sitesi Erişim Kayıtlarının Web Madenciliği İle Analizi. Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya, 80s.
- Aslan, E. (2017). Tedarik Zinciri Yönetimi –Kurumsal Sistem Entegrasyonu ve Tedarik Zinciri Kaynak Planlaması. Enderun Dergisi, 1(2), 9–16.
- Atkeson, C. G., Moore, A. W., & Schaal, S. (1997). Locally weighted learning. In Springer eBooks (ss. 11–73). https://doi.org/10.1007/978-94-017-2053-3_2.
- Ayers, J. B., (2000). Handbook of Supply Chain Management, St. Lucie Press, London, 2000.
- Ballou, R. H. (2004). Business Logistics/Supply Chain Management: Planning, organizing, and controlling the supply chain. Upper Saddle River (NJ), Upper Saddle River (NJ): Pearson Education.
- Baykal, A., (2006). Veri Madenciliği Uygulama Alanları, Ziya Gökalp Eğitim Fakültesi Dergisi (7), 95-107.
- Bayram Durna, M. (2020). Cross-Validation nedir? Nasıl çalışır? <https://medium.com/bili%C5%9Fim-hareketi/cross-validation-nedir-nas%C4%B1l-%C3%A7al%C4%B1%C5%9F%C4%B1r-4ec4736e5142>
- Berchet, C., & Habchi, G. (2005). The implementation and deployment of an ERP system: An industrial case study. *Computers in Industry*, 56(6), 588–605. <https://doi.org/10.1016/j.compind.2005.02.009>.

- Bielza, C., & Larrañaga, P. (2014). Discrete Bayesian network classifiers. *ACM Computing Surveys*, 47(1), 1–43. <https://doi.org/10.1145/2576868>.
- Bozkurt Uzan, Ş. and Özüçağlıyan, (2020). Data Mining in Tourism Sector, *Journal of Turkish Tourism Research*, 4(4): 3465-3485.
- Bu, S., (2021). Logistics engineering optimization based on machine learning and artificial intelligence technology. *Journal of Intelligent & Fuzzy Systems*, vol. 40, no. 2, pp. 2505-2516.
- Buja, A., & Stuetzle, W. (2006). OBSERVATIONS ON BAGGING. *Statistica Sinica*, 16(2), 323–351.
- Bhardwaj, C. A., Mishra, M., & Desikan, K. (2018). Dynamic feature scaling for K-Nearest Neighbor algorithm. Cornell University. <https://doi.org/10.48550/arxiv.1811.05062>
- Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24(2), 123–140. <https://doi.org/10.1007/bf00058655>.
- Bryan, N., & Srinivasan, M. M. (2014). Real-time order tracking for supply systems with multiple transportation stages. *European Journal of Operational Research*, 236(2), 548–560. <https://doi.org/10.1016/j.ejor.2014.01.062>.
- Canpolat, M. (2014). Kurumsal Kaynak Planlaması (ERP) Ve Türkiye Radyo Ve Televizyon (TRT) Kurumu Uygulaması. Doktora Tezi, Türk Hava Kurumu Üniversitesi Sosyal Bilimler Enstitüsü, Ankara.
- Centner, V., & Massart, D. L. (1998). Optimization in locally weighted regression. *Analytical Chemistry*, 70(19), 4206–4211. <https://doi.org/10.1021/ac980208r>.
- Celebi, M. E., Kingravi, H. A., & Vela, P. A. (2013). A comparative study of efficient initialization methods for the k-means clustering algorithm. *Expert Systems With Applications*, 40(1), 200–210. <https://doi.org/10.1016/j.eswa.2012.07.021>.
- Cunningham, P., & Delany, S. J. (2007). k-Nearest Neighbour Classifiers. University College Dublin. School of Computer Science and Informatics.
- Cunningham, P., & Delany, S. J. (2021). K-Nearest Neighbour Classifiers - a tutorial. *ACM Computing Surveys*, 54(6), 1–25. <https://doi.org/10.1145/3459665>.

- Congna, Q., Huifeng, Z. Bo, L. (2009, May). Study on application of data mining technology to modern logistics management decision. In 2009 International Forum on Information Technology and Applications (Vol. 3, 433-436). IEEE.
- Chen, L., Sakaguchi, T., Frolick M., (2006). Data Mining Methods, Applications, and Tools. *Information Systems Management*, 17, 65–70.
- Cheng, J., Greiner, R. (2001). Learning Bayesian Belief Network Classifiers: Algorithms and System. In: Stroulia, E., Matwin, S. (eds) *Advances in Artificial Intelligence. Canadian AI. Lecture Notes in Computer Science()*, vol 2056. Springer, Berlin, Heidelberg. https://doi.org/10.1007/3-540-45153-6_14.
- Chengsheng, T., Huacheng, L., & Bing, X. (2017). AdaBoost typical Algorithm and its application research. *MATEC Web of Conferences*, 139, 00222. <https://doi.org/10.1051/mateconf/201713900222>
- Christopher, M., (2011). *Logistics and Supply Chain Management*. 4th Edition, Pearson Education Limited, 13.
- Chopra, S., and Meindl, P. (2001). Supply chain management: strategy. *Planning and Operation*, 15(5): 71-85.
- Çınar, A. (2019). Veri Madenciliğinde Sınıflandırma Algoritmalarının Performans Değerlendirmesi ve R Dili İle Bir Uygulama. *Öneri Dergisi/Öneri*, 14(51), 90–111. <https://doi.org/10.14783/maruoneri.vi.522168>
- Çınar, A. C. (2017). k-kez çapraz doğrulama yöntemi. <https://www.ahmetcevahircinar.com.tr/2017/03/25/k-kez-capraz-dogrulamayontemi/>
- Dağdeviren, M. ve Eren, T., (2001). “Tedarikçi Firma Seçiminde Analitik Hiyerarşi Prosesi ve 0-1 Hedef Programlama Yöntemlerinin Kullanılması”, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 16(2), ss. 41-52.
- Dalkılıç, H., & Dalkılıç, F., (2015). *Karar Ağaçları Destekli Vadeli Mevduat Analizi* . XVII. Akademik Bilişim Konferansı, Eskişehir, Türkiye.
- Das, N. (2020). Supplier Selection Criteria and Methods in Supply Chain (A Statistical Approach). *Proceedings of the 3rd Asia Pacific Management Research Conference (APMRC 2019)*. <https://doi.org/10.2991/aebmr.k.200812.002>.

- Davidson, I., & Fan, W. (2006). When efficient model averaging Out-Performs boosting and bagging. In *Lecture notes in computer science* (pp. 478–486). https://doi.org/10.1007/11871637_46.
- Demir, H. (2021, January 17). Python üzerinde Naive Bayes kullanarak otel değerlendirme yapmak. Ravenfo. <https://ravenfo.com/2018/10/10/python-uzerinde-naive-bayes-kullanarak-otel-degerlendirmesi-yapmak/>. Erişim Tarihi: 18.08.2024
- Demirdöğen, O. & Küçük, O., (2007). “Malzeme Akışının Etkinliğinde Tedarik Zinciri Yönetiminin Önemi”, 8.Türkiye Ekonometri ve İstatistik Kongresi, Malatya, İnönü Üniversitesi, ss. 1-13.
- Dey, P. K., Bhattacharya, A., Ho, W., & Clegg, B. (2015). Strategic supplier performance evaluation: A case-based action research of a UK manufacturing organisation. *International Journal of Production Economics*, 166, 192–214. <https://doi.org/10.1016/j.ijpe.2014.09.021>.
- Efrilianda, D. A., Mustafid, N., & Isnanto, R. R. (2018). Inventory control systems with safety stock and reorder point approach. *2018 International Conference on Information and Communications Technology (ICOIACT)*. <https://doi.org/10.1109/icoiact.2018.8350766>.
- Elbiad, Z. (2013). Web Tabanlı Anket Sistemi ile Elde Edilen Verilerin Veri Madenciliği Yöntemi ile Analizi. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, İstanbul, 7–11.
- Englert, P. (2012). “Locally weighted learning,” in Seminar Class on Autonomous Learning Systems. CiteSeer.
- Ersöz, F. (2019). Veri madenciliği teknikleri ve uygulamaları. (3. Baskı). Seçkin Yayıncılık.
- Eymen, U. Erman (2007). Tedarik Zinciri Yönetimi. Kalite Ofisi Yayınları, (14), 5-51.
- Fıçrı, G., (2006). Tedarikçi Yönetiminde Envanter Kontrolü, Yüksek Lisans Tezi, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- Fink, A., Sebastian, H., & Voß, S. (2012). Introduction to Intelligent Decision Support for Logistics and Supply Chain Management Minitrack. *45th Hawaii International Conference on System Sciences*. <https://doi.org/10.1109/hicss.2012.358>
- Fugate, B., Sahin, F., & Mentzer, J. T. (2006). Supply chain management coordination mechanisms. *Journal of Business Logistics*, 27(2), 129-161.

- Flight, L., & Julious, S. A. (2014). The disagreeable behaviour of the kappa statistic. *Pharmaceutical Statistics*, 14(1), 74–78. <https://doi.org/10.1002/pst.1659>.
- Franco, F., & Di Napoli, A. (2016). Valutazione della riproducibilità di una misura: la statistica Kappa. *Giornale Di Clinica Nefrologica E Dialisi*, 28(4), 289–292. <https://doi.org/10.33393/gcnd.2016.738>.
- Frank, E., Hall, M., & Pfahringer, B. (2002). Locally weighted naive bayes. Cornell University, 249–256.
- Freund, Y., & Schapire, R. E. (1997). A Decision-Theoretic generalization of On-Line learning and an application to boosting. *Journal of Computer and System Sciences*, 55(1), 119–139. <https://doi.org/10.1006/jcss.1997.1504>
- Gedikli, D.C., (2006). “İnternet Tabanlı Tedarik Zinciri Yönetiminin KOBİ’lerde Uygulanması İçin Bir Model Önerisi”, Doktora Tezi, Erciyes Üniversitesi Sosyal Bilimler Üniversitesi, Kayseri.
- Govindan, K., Cheng, T., Mishra, N., & Shukla, N. (2018). Big data analytics and application for logistics and supply chain management. *Transportation Research. Part E, Logistics and Transportation Review*, 114, 343–349. <https://doi.org/10.1016/j.tre.2018.03.011>
- Gultom, G. D. P., & Wibisono, E. (2019). A framework for the impact of lean six sigma on supply chain performance in manufacturing companies. *IOP Conference Series. Materials Science and Engineering*, 528(1), 012089. <https://doi.org/10.1088/1757-899x/528/1/012089>.
- Guo, X., Liu, C., Xu, W., Yuan, H., & Wang, M. (2014). A Prediction-Based Inventory Optimization Using Data Mining Models. *2014 Seventh International Joint Conference on Computational Sciences and Optimization*. <https://doi.org/10.1109/cso.2014.118>
- Güleş, H.K., Paksoy, T., Bülbül H. ve Özceylan, E., 2009. Tedarik Zinciri Yönetimi: Stratejik Planlama, Modelleme ve Optimizasyon, Gazi Kitabevi, Ankara.
- Gürsoy, İ. (2019). Pay Senedi Fiyatlarını Etkileyen Değişkenlerin C4.5 Karar Ağacı Algoritması ile Modellenmesi. Doktora Tezi, Zonguldak Bülent Ecevit Üniversitesi Sosyal Bilimler Enstitüsü, Zonguldak.
- Grandvalet, Y. (2004). Bagging equalizes influence. *Machine Learning*, 55(3), 251–270. <https://doi.org/10.1023/b:mach.0000027783.34431.42>.

- Hamerly, G., & Elkan, C. (2003). Learning the k in k-means. *Neural Information Processing Systems*, 16, 281–288.
- Han J., Kamber M., (2001) “Data Mining Concepts and Techniques”, Morgan Kaufmann Publishers, U.S.A.
- Hasan, M. R., Siraj, F., & Sainin, M. S. (2015). Improving ensemble decision tree performance using Adaboost and Bagging. *AIP Conference Proceedings*. <https://doi.org/10.1063/1.4937027>.
- Helo, P., & Hao, Y. (2021). Artificial intelligence in operations management and supply chain management: an exploratory case study. *Production Planning & Control*, 33(16), 1573–1590. <https://doi.org/10.1080/09537287.2021.1882690>.
- Hill, C.A. (1998). Supply Chain: Just Do Something, *Automatic ID News*, 14(1), 36-38.
- Hossin, M., & Sulaiman, M. N. (2015). A Review on Evaluation Metrics for Data Classification Evaluations. *International Journal of Data Mining & Knowledge Management Process*, 5(2), 01–11. <https://doi.org/10.5121/ijdkp.2015.5201>.
- Houlihan, J.B. (1985), "International Supply Chain Management", *International Journal of Physical Distribution & Materials Management*, Vol. 15 No. 1, pp. 22-38. <https://doi.org/10.1108/eb014601>
- Hubar, A. (2006). Dağıtım Yönetim Sistemi Tasarımı Ve Yazılım Geliştirme. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul. <http://hdl.handle.net/11527/5833>.
- Huang, C., Luo, L., & Nie, Y. (2022). Research on the Application of Data Mining Technology in Enterprise Supply Chain Management System. *International Conference on Cloud Computing, Big Data Applications and Software Engineering (CBASE)*. <https://doi.org/10.1109/cbase57816.2022.00035>.
- Hutasoit, M., N., Fa’rifah R., Y., ve Andreswari R. (2023). “Application of Data Mining For Clustering Car Sales Using The K-Means Clustering Algorithm”. *International Journal of Information System & Technology*. Vol. 7, No. 2, (2023), pp. 118-124.
- İşler, Y., & Narin, A. (2012). Weka Yazılımında K-Ortalama Algoritması Kullanılarak Konjestif Kalp Yetmezliği Hastalarının Teşhisi. *SDÜ Teknik Bilimler Dergisi*, 2(4), 21–29. <http://www.cs.waikato.ac.nz/ml/weka>

- Jivani, A. G. (2013). The Novel k Nearest Neighbor Algorithm. 2013 International Conference on Computer Communication and Informatics. <https://doi.org/10.1109/iccci.2013.6466287>
- Kabakchieva D. (2015). Business Intelligence Systems for Analyzing University Students Data. *Cybernetics and Information Technologies*, 15(1): 104-115.
- Kang, K., & Michalak, J. (2018). Enhanced version of AdaBoostM1 with J48 Tree learning method. *ArXiv*, *abs/1802.03522*.
- Kantardzic, M. (2003). Data Mining: Concepts, models, methods, and algorithms. *Technometrics*, 45(3), 277.
- Kağmıçoğlu, C.H., (2007). Tedarik Zinciri Yönetiminde Tedarikçi Seçimi, T.C. Anadolu Üniversitesi Yayınları, Eskişehir, 210.
- Kara, K.; P. Yücekaya (2021) “Current Economics Management Sciences Research”, The Mediator Effect of Technological Innovation on the Relationship Between Supply Chain Management Practices and Firm Performance, Ed.:Nuriye Güneş, Lyon, Livre de Lion, ss. 101-132.
- Keçek, G., & Yıldırım, E. (2009). Kurumsal Kaynak Planlaması (Erp) ve İşletme Açısından Önemi. *Elektronik Sosyal Bilimler Dergisi*, 8(29), 240-258.
- Kehoe, D., and Boughton, N. (2001). Internet based supply chain management: A classification of approaches to manufacturing planning and control. *International Journal of Operations & Production Management*.
- Kelly, A., & Johnson, M. A. (2021). Investigating the Statistical Assumptions of Naïve Bayes Classifiers. 2021 55th Annual Conference on Information Sciences and Systems (CISS). <https://doi.org/10.1109/ciss50987.2021.9400215>.
- Koçarslan, H., Gedik, A., ve Koçak, Ş. (2023). “Tedarik Zincirinde Yapay Zeka”. *Sosyal Bilimlerde Güncel Çalışmalar-3*, ss. 203-222. www.iksadyayinevi.com.
- Kopczak, L.R. (1997), “Logistics partnership and supply chain restructuring. survey results from the US computer industry” *Production and Operations Management*, Vol.6 No.3, pp.226-247.

- Kotler, P.& Armstrong, G. (2012). Principles of Marketing. Pearson Education, Fourteenth Edition.
- Kumar V., Reinartz W. (2018) Data Mining. In: Customer Relationship Management. Springer Texts in Business and Economics. Springer, Berlin, Heidelberg
- Kunt, M. S. (2019). Telekomünikasyon Sektöründe Müşteri Kaybı Analizi. Yüksek Lisans Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Küçük, O. (2017). Stok Yönetimi: Amprik Bir Yaklaşım. Seçkin Yayıncılık.
- Küçükönder, H., Vursavuş, K. K., & Üçkardeş, F. (2015). K-Star, Rastgele Orman ve Karar Ağacı (C4.5) Sınıflandırma Algoritmaları ile Domatesin Renk Olgunluğu Üzerinde Bazı Mekanik Özelliklerin Etkisinin Belirlenmesi. Türk Tarım- Gıda Bilim ve Teknoloji Dergisi, 3(5), 300–306. www.agrifoodscience.com
- Klanke, S., Vijayakumar, S., & Schaal, S. (2008). A library for locally weighted projection regression. Journal of Machine Learning Research, 9(21), 623–626.
- Lambert, D. M., Stock, J. R., and Ellram, L. M., (1998). Fundamentals of Logistics Management, MA: Irwin/McGraw-Hill, Boston,
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. Biometrics, 33(1), 159. <https://doi.org/10.2307/2529310>.
- Langley, C.J., Coyle, J.J., Gibson, B.J., Novack ,R.A. & Bardi, E.J. (2008). Managing Supply Chains: A Logistics Approach. Kanada:South-Westerns Cengage Learning, 17.
- Larose, T.D. (2005). Discovering Knowledge In Data: An Introduction To Data Mining. New Jersey: A. John Willey&Sons, Inc.
- Lee, H., & Kopczak, L. (1997). Responding to the Asia-Pacific challenge. Supply Chain Management Review, Spring, Vol.1, No.1, 8-9
- Lee, H. L., And C. Billington. 1992. Supply Chain Management: Pitfalls and Opportunities. Sloan Mgmt. Rev. 33, Spring, 65-73.
- Li, G. G., Zhou, J. Y., & Yang, T. (2014). The research of inventory management based on the supply chain. *Applied Mechanics and Materials*, 687–691, 5116–5119. <https://doi.org/10.4028/www.scientific.net/amm.687-691.5116>.

- Li, Y., X. Zhao, D. Shi, and X. Li. 2014. "Governance of Sustainable Supply Chains in the Fast Fashion Industry." *European Management Journal* 32 (5):823–836. (PDF) *Strategic approaches to sustainability in fashion supply chain management*. Available from: https://www.researchgate.net/publication/319675958_Strategic_approaches_to_sustainability_in_fashion_supply_chain_management
- Linden, A. (1999). CIO update: Data mining applications of the next decade. *Inside Gartner Group, Gartner Inc., July, 7*.
- Lummus, Rhonda R., & Vokurka, R. J. (1999). Defining supply chain management: a historical perspective and practical guidelines. *Industrial Management & Data Systems*, 99(1), 11-17. <https://doi.org/10.1108/02635579910243851>.
- Lysons, K., (2000), *Purchasing and Supply Chain Management*, Fifth Edition, Prentice Hall, England.
- Markland, R. E., Vickery, S. K., Davis, R. A. (1998). *Operations Management* (pp 101).2nd ed., ITP South-Western College Publishing, Cincinnati, Ohio, USA.
- Martin, C., & Towill, D. R. (2000). Supply chain migration from lean and functional to agile and customized. *Supply Chain Management: An International Journal*, 5(4), 206-213. doi:10.1108/13598540010347334
- Metsis, V., Androutopoulos, I., & Paliouras, G. (2006). Spam Filtering with Naive Bayes - Which Naive Bayes? *Conference on Email and Anti-Spam*.
- Metz, Peter J. (1998). Demystifying supply chain management. *Supply Chain Management Review*, V. 1, No. 4 (Winter 1998), P. 46-55: Ill.
- Min, H. (2009). Artificial intelligence in supply chain management: theory and applications. *International Journal of Logistics*, 13(1), 13–39. <https://doi.org/10.1080/13675560902736537>
- Mou, A. D., Saha, P. K., Nisher, S. A., & Saha, A. (2021). A Comprehensive Study of Machine Learning algorithms for Predicting Car Purchase Based on Customers Demands. 2021 International Conference on Information and Communication Technology for Sustainable Development (ICICT4SD). <https://doi.org/10.1109/icict4sd50815.2021.9396868>.

- Mucherino, A., Papajorgji, P. J., & Pardalos, P. M. (2009). K-Nearest Neighbor Classification. In Springer optimization and its applications (pp. 83–106). https://doi.org/10.1007/978-0-387-88615-2_4.
- Mukid, M. A., Widiari, T., Rusgiyono, A., & Prahutama, A. (2018). Credit scoring analysis using weighted k nearest neighbor. *Journal of Physics Conference Series*, 1025, 012114. <https://doi.org/10.1088/1742-6596/1025/1/012114>.
- Murat, Y. S. (2006). *Tedarik Zinciri Yönetiminde Tedarikçi Performansı Değerlendirme ve Tedarikçi Sayısının Azaltılması* (Doctoral dissertation, Fen Bilimleri Enstitüsü).
- McClain, J.O., Thomas, L.J., Mazzola, J.B., 1992. *Operations Management*. 3 th Edition, NJ: Prentice Hall.
- McGinn, T., Wyer, P. C., Newman, T. B., Keitz, S., Leipzig, R., & For, G. G. (2004). Tips for learners of evidence-based medicine: 3. Measures of observer variability (kappa statistic). *Canadian Medical Association Journal*, 171(11), 1369–1373. <https://doi.org/10.1503/cmaj.1031981>.
- McHugh, M. L. (2012). Interrater reliability: the kappa statistic. *Biochemia Medica*, 276–282. <https://doi.org/10.11613/bm.2012.031>.
- McLARNY, Carolan (2001), “Strategic planning-effectiveness-environment linkage: a case study”, *Management Decision*, 39/10, s. 809-817.
- Na, N. W., & Wang-Ping, N. (2010). Quality of learning analysis based on Bayesian Network. *International Conference on Computer Design and Applications*. <https://doi.org/10.1109/iccda.2010.5540920>.
- Orhon, O. Z. (2003). Dünya’da ve Türkiye’de Lojistik Sektörünün Gelişimi. İTO, İstanbul.
- Özceylan, E., (2010). “Tedarik Zinciri Yönetiminde Üretim/Dağıtım Ağlarının Tasarımına Yeni Model Yaklaşımları” Yüksek Lisans Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Özdemir, A.İ., (2004). “Tedarik Zinciri Yönetiminin Gelişimi, Süreçleri ve Yararları”, *Erciyes Üniversitesi İİBF Dergisi*, (23), ss. 87-96.

- Özdemir, E., & Ballı, S. (2020). Türkiye Erkekler Basketbol Ligi Maç Sonuçlarının Makine Öğrenmesi Yöntemleri İle Tahmini. *Mühendislik Bilimleri ve Tasarım Dergisi*, 8(3), 740–752. <https://doi.org/10.21923/Jesd.723109>
- Özgen, H., Yalçın A., (2006), Temel İşletmecilik Bilgisi, Nobel, 3. Baskı, Adana.
- Özkan, O., Bayın, G., and Yeşilaydin, G. (2015). Sağlık sektöründe yalın tedarik zinciri yönetimi. *AJIT-e: Bilişim Teknolojileri Online Dergisi*, 6(18): 71-94.
- Öztürk, K., & Şahin, M. E. (2018). Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış. *Takvim-I Vekayi*, 6(2), 25-36.
- Özyirmidokuz K. E. (2009). Veri madenciliği tekniklerini kullanarak imalat verilerinin modellenmesi ve analizi. Doktora Tezi, Erciyes Üniversitesi Sosyal Bilimler Enstitüsü, Kayseri, 39-60.
- Pagani, M., (2005). *Mobile And Wireless Systems Beyond 3G: Managing New Business Opportunities*. IRM Press, Italy.
- Panda, S. K. (2022). Car Buying Criteria Evaluation Using Machine Learning Approach. *The New Advanced Society*, 223–245. <https://doi.org/10.1002/9781119884392.ch10>.
- Pang-Ning Tan, P. N., Steinbach, M., Kumar, V. (2006). *Introduction to Data Mining*. Addison Wesley, 769 pp.
- Park, K. J. (2021). Determining the tiers of a supply chain using machine learning algorithms. *Symmetry*, 13(10), 1934. <https://doi.org/10.3390/sym13101934>.
- Park, S. C., Piramuthu, S., & Shaw, M. J. (2001). Dynamic rule refinement in knowledge-based data mining systems. *Decision Support Systems*, 31(2), 205-222. [https://doi.org/10.1016/S0167-9236\(00\)00132-9](https://doi.org/10.1016/S0167-9236(00)00132-9)
- Parveen, C. M., Kumar, A. R. P., & Rao, T. V. V. L. N. (2011). Integration of lean and green supply chain - Impact on manufacturing firms in improving environmental efficiencies. *International Conference on Green Technology and Environmental Conservation (GTEC-2011)*. <https://doi.org/10.1109/gtec.2011.6167659>.
- Patel, D., Bothra, J., & Patel, V. (2017). Blockchain Exhuned. 2017 ISEA Asia Security and Privacy (ISEASP), (s. 1-12).

- Paul, S. K., & Azaem, A. (2011). An artificial neural network model for optimization of finished goods inventory. *International Journal of Industrial Engineering Computations*, 2(2), 431–438. <https://doi.org/10.5267/j.ijiec.2011.01.005>
- Paulraj, A., & Chen, I. J. (2007). Strategic buyer–supplier relationships, information technology and external logistics integration. *Journal of Supply Chain Management*, 43(2), 2-14.
- Peng, Hanchuan, Fuhui Long, and Chris Ding. "Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy." *IEEE Transactions on Pattern Analysis and Machine Intelligence* 27.8 (2005): 1226-1238.
- Poirier, C C (1999). *Advanced Supply Chain Management:How to Build a Sustained Competitive Advantage*, SanFrancisco: Berrett-Koehler Publishers, Inc.
- Priniotakis, G., & Argyropoulos, P. (2018). Inventory management concepts and techniques. *IOP Conference Series. Materials Science and Engineering*, 459, 012060. <https://doi.org/10.1088/1757-899x/459/1/012060>.
- Quinn, F.J., (1997), " What's the buzz? ", *Logistics Management*, 36, 2, 43-7.
- Raschka, S. (2014). *Naive Bayes and Text Classification I - Introduction and Theory*.mCornell University. <https://doi.org/10.48550/arxiv.1410.5329>.
- Rennie, J. D. M. (2001). Improving multi-class text classification with Naive Bayes. <http://dspace.mit.edu/bitstream/handle/1721.1/7074/ai-tr-2001-004.pdf?sequence=2>.
- Robbins, Stephen P., David A. Decenzo (2004), *Fundamentals of Management*, Prentice Hall, New Jersey.
- Romano, P. (2003) “Co-ordination and Integration Mechanisms to Manage Logistics Processes Across Supply Networks”, *Journal of Purchasing and Supply Management*, Vol.9, No.3, ss.119-134.
- Russell, R. S., Taylor, B. W., (2009) “Operations Management along the Supply Chain,” 6th Edition, John wiley and Sons Ltd., Chichester.
- Sadiku, M. N., Shadare, A. E., & Musa, S. M. (2015). Data mining: A brief introduction. *European Scientific Journal*, 11(21).
- Safranski, S. ve Kwon, W. (1991). *How to write a business plan?*. Boston: Linda Pinson And Jerry Kinnet Pres. USA.

- Sarıman, G. (2014). Veri Madenciliğinde Kümeleme Teknikleri Üzerine Bir Çalışma: K-Means ve K-Medoids Kümeleme Algoritmalarının Karşılaştırılması. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 15(3), 192-202. <https://doi.org/10.19113/sdufbed.41288>
- Satyananda, D., & Abdullah, A. (2021). Deep Learning to Handle Congestion in Vehicle Routing Problem: A review. *Journal of Physics. Conference Series*, 2129(1), 012023. <https://doi.org/10.1088/1742-6596/2129/1/012023>.
- Savaş, S., (2020). Veri Madenciliği. <https://medium.com/veri-madencili%C4%9Fi/veri-madencili%C4%9Fi-f8d406767809>
- Seewald, A. K. (2007). An evaluation of Naive Bayes variants in content-based learning for spam filtering. *Intelligent Data Analysis*, 11(5), 497–524. <https://doi.org/10.3233/ida-2007-11505>
- Sevinç N., (2008). Tedarik Zinciri Yönetiminde Bilgi Teknolojilerinin Kullanılması ve Önemi, Yüksek Lisans Tezi, Trakya Üniversitesi Sosyal Bilimler Enstitüsü İşletme Ana Bilim Dalı, Edirne.
- Seyedan, M., Mafakheri, F. Predictive big data analytics for supply chain demand forecasting: methods, applications, and research opportunities. *J Big Data* 7, 53 (2020). <https://doi.org/10.1186/s40537-020-00329-2>.
- Seylan, Ç., Bican, Ö. S., & Semiz, F. (2020). İnsansız araçlarla düzlemsel olmayan araçların taranması. Cornell University. <https://doi.org/10.48550/arxiv.2003.09310>.
- Soori, M., Arezoo, B., & Dastres, R. (2023). Artificial neural networks in supply chain management, a review. *Journal of Economy and Technology*, 1, 179–196. <https://doi.org/10.1016/j.ject.2023.11.002>
- Su, Y. F., & Yang, C. (2010). A structural equation model for analyzing the impact of ERP on SCM. *Expert Systems with Applications*, 37(1), 456-469.
- Suryadi, D., Tan, A., & Boy, D. (2021). A data mining approach to predicting the inventory day of used cars. *International Journal of Knowledge Engineering and Data Mining*, 7(1/2), 127. <https://doi.org/10.1504/ijkedm.2021.119887>
- Scheuing, E. E. (1998). *Value-added purchasing: Partnering for World-class Performance*. Crisp Pub Incorporated.

- Shapiro, B.P., Rangan, V.K. & Sviokla, J.J. (1992). Staple Yourself to an Order, Harvard Business Review, 70 (4), 113–122.
- Stevens, G. C. (1989) “Integrating the Supply Chain”, International Journal of Physical Distribution and Materials Management, Vol.19, No.8, ss.3-8.
- Svensso, G. (2002). “The Theoretical Foundation of Supply Chain Management”, International Journal of Physical Distribution and Logistics Management, Vol.32, No.9, ss.734-754.
- Şen, E. (2006). “Kobi’lerin Uluslararası Rekabet Güçlerini Arttırmada Tedarik Zinciri Yönetiminin Önemi”, T.C. Başbakanlık Dış Ticaret Müsteşarlığı İhracatı Geliştirme Etüd Merkezi.
- Şeker, E.Ş. (2008). “KNN (K nearest neighborhood, en yakın k komşu)”. Bilgisayar Kavramları. <https://bilgisayarkavramlari.com/2008/11/17/knn-k-nearest-neighborhood-en-yakin-k-komsu/>.
- Şirin, E. (2017). Bir Bakışta K-Fold Cross Validation - Veri Bilimi Okulu - Veri Bilimi Okulu. <https://www.veribilimiokulu.com/bir-bakista-k-fold-cross-validation/>
- Tapkan, P., Özbakır, L., & Baykasoğlu, A. (2011). Weka ile Veri Madenciliği Süreci ve Örnek Uygulama. Endüstri Mühendisliği Yazılımları ve Uygulamaları Kongresi, İzmir, 247–262.
- Teigen, R. (2000), “Supply Chain Management Introduction. International Journal of Flexible Manufacturing Systems, April 2000, s. 12-40.
- Teuteberg, F. (2008). Supply Chain Risk Management: A Neural Network Approach. *Strategies and Tactics in Supply Chain Event Management*, 99 - 118.
- Timur, M. ve diğerleri (2013) Tedarik Zinciri Yönetimi, Eskişehir, Anadolu Üniversitesi.
- Top, A. (2006). Üretim Yönetimi, Nobel Yayın Dağıtım, Ankara, s.191-204.
- Türköz, Ö. (2007). Tedarik Zinciri Yönetiminde Dağıtım Gereksinim Planlaması. Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Tüysüzoğlu, G., & Birant, D. (2020). Enhanced bagging (eBagging): a novel approach for ensemble learning. The International Arab Journal of Information Technology, 17(4), 515–528. <https://doi.org/10.34028/iajit/17/4/10>.

- Uran, Eren (2004). Yük Ulaştırması ve Coğrafi Bilgi Sistemleri. Yüksek Lisan Tezi. Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü: 17.
- Usama F., Paul S., "Data Mining and KDD: Promise and Challenges," *Future Generation Computer Systems*, No: 13, 1997, s. 102.
- Uslu, M. (2019). Weka ile Birliktelik Kuralları Analizi (Association Rules Analysis With Weka)- Veri Bilimi Okulu- Veri Bilimi Okulu. Veri Bilimi Okulu. <https://www.veribilimiokulu.com/association-rules-analysis-with-weka/>
- Uzun, R., Isler, Y., & Toksan, M. (2018). Choose of wart treatment method using Naive Bayes and k-nearest neighbors classifiers. 2018 26th Signal Processing and Communications Applications Conference (SIU). <https://doi.org/10.1109/siu.2018.8404398>.
- Vidal, G. H., Villadiego, D. J., & Calle, M. M. (2019). Inventory management in Manufacturing Systems: A Literature Review. *Indian Journal of Science and Technology*, 13(12), 1–13. <https://doi.org/10.17485/ijst/2019/v12i13/132758>.
- Viera, A. J., & Garrett, J. M. (2005). Understanding interobserver agreement: the kappa statistic. *PubMed*, 37(5), 360–363. <https://pubmed.ncbi.nlm.nih.gov/15883903>.
- Vijayakumar, S., D’Souza, A., & Schaal, S. (2005). Incremental online learning in high dimensions. *Neural Computation*, 17(12), 2602–2634. <https://doi.org/10.1162/089976605774320557>.
- Vollmann, T., Berry, W., Whybark, D. C., & Jacobs, F. R. (2004). Manufacturing planning and control systems for supply chain management: the definitive guide for professionals. *McGraw-Hill Professional*, 5.
- Vranic, M., Pintar, D., & Skocir, Z. (2007). The use of data mining in education environment. 2007 9th International Conference on Telecommunications, 243– 250. <https://doi.org/10.1109/CONTEL.2007.381878>
- Yıldızöz, H., (2006). Tedarik Zinciri Yönetimi ve Bir Uygulama, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Yıldız, M., Şeker, Ş. E., (2016). “Veri Madenciliği Araçları (Data Mining Tools)”. *YBS Ansiklopedi*, 3(4), 10-19. www.YBSAnsiklopedi.com.

- Zou, H., & Zhang, T. (2018). Research on Vehicle Routing Algorithm for Supply Chain Logistics Distribution. *MATEC Web of Conferences*, 227, 02003. <https://doi.org/10.1051/mateconf/201822702003>
- Zhong, C., Chen, Y., & Peng, J. (2020). Feature selection based on a novel improved tree growth algorithm. *International Journal of Computational Intelligence Systems*, 13(1), 247. <https://doi.org/10.2991/ijcis.d.200219.001>.
- Zsidisin, G., A., ve B. Ritchie, (2009), Supply Chain Risk Management: Developments, Issues and Challenges, In Supply Chain Risk: A Hvebook of Assessment, Management and Performance, Springer, New York.
- Wah, Y. B., Ismail, N. H., & Fong, S. (2011). Predicting car purchase intent using data mining approach. 2011 Eighth International Conference on Fuzzy Systems and Knowledge Discovery (FSKD). <https://doi.org/10.1109/fskd.2011.6019863>.
- Wankhade, N., & Kundu, G. K. (2018). Supply chain performance management: a structured literature review. *International Journal of Value Chain Management*, 9(3), 209. <https://doi.org/10.1504/ijvcm.2018.093885>.
- Witten I.H., Frank E., Hall MA. (2011). Data mining: practical machine learning tools and techniques. Elsevier, London.
- Wickramasinghe, I., & Kalutarage, H. (2020). Naive Bayes: applications, variations and vulnerabilities: a review of literature with code snippets for implementation. *Soft Computing*, 25(3), 2277–2293. <https://doi.org/10.1007/s00500-020-05297-6>
- Wu, M., & Weng, Y. (2010). A study of supplier selection factors for high-tech industries in the supply chain. *Total Quality Management and Business Excellence/Total Quality Management & Business Excellence*, 21(4), 391–413. <https://doi.org/10.1080/14783361003606662>.
- Xie, Z. (2009). Improved AdaBoost.M1 of decision trees with confidence-rated predictions. *Association for Computing Machinery*. <https://doi.org/10.1145/1529282.1529608>.

<https://www.kaggle.com/datasets/>. Erişim Tarihi: 04.02.2022

www.beyaz.net. Erişim Tarihi: 01.02.2023

<https://weka.sourceforge.io/doc.dev/weka/classifiers/meta/AdaBoostM1.html>. Erişim

Tarihi: 15.05.2023

<https://www.cs.cmu.edu/afs/cs/project/jair/pub/volume4/cohn96a-html/node7.html>

Erişim Tarihi: 15.07.2024

<https://medium.com/syncedreview/infiniteboosting-a-bagging-boosting-hybrid-algorithm-8b109019e480> Erişim Tarihi: 15.08.2024

<https://www.cs.cmu.edu/afs/cs/project/jair/pub/volume11/opitz99a-html/node3.html>.

Erişim Tarihi: 16.08.2024

<https://weka.sourceforge.io/doc.dev/weka/classifiers/meta/AdaBoostM1.html>. Erişim

Tarihi: 17.08.2024