



**PAZAR SEPETİ ANALİZİ İLE BİRLİKTELİK
KURALLARININ BELİRLENMESİ: PERAKENDE
SEKTÖRÜNDE COVID-19 ETKİSİ**

Ezgi ALANLAR

**2021
YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ**

**Tez Danışmanı
Prof. Dr. Filiz ERSÖZ**

**PAZAR SEPETİ ANALİZİ İLE BİRLİKTELİK KURALLARININ
BELİRLENMESİ: PERAKENDE SEKTÖRÜNDE COVID-19 ETKİSİ**

Ezgi ALANLAR

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Endüstri Mühendisliği Anabilim Dalında
Yüksek Lisans Tezi
Olarak Hazırlanmıştır**

**Tez Danışmanı
Prof. Dr. Filiz ERSÖZ**

**KARABÜK
Ocak 2021**

Ezgi ALANLAR tarafından hazırlanan “ PAZAR SEPETİ ANALİZİ İLE BİRLİKTE LİK KURALLARININ BELİRLENMESİ: PERAKENDE SEKTÖRÜNDE COVID-19 ETKİSİ ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Prof. Dr. Filiz ERSÖZ

.....

Tez Danışmanı, Endüstri Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından oy birliği ile Endüstri Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 21/01/2021

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Prof. Dr. Emel KIZILKAYA AYDOĞAN (ERÜ)

.....

Üye : Prof. Dr. Filiz ERSÖZ (KBÜ)

.....

Üye : Doç. Dr. Taner ERSÖZ(KBÜ)

.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ

.....

Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Ezgi ALANLAR

ÖZET

Yüksek Lisans Tezi

PAZAR SEPETİ ANALİZİ İLE BİRLİKTELİK KURALLARININ BELİRLENMESİ: PERAKENDE SEKTÖRÜNDE COVID-19 ETKİSİ

Ezgi ALANLAR

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı:

Prof. Dr. Filiz ERSÖZ

Ocak 2021, 108 sayfa

Bilgisayar sistemleri sayesinde çok fazla miktarda veri kayıt altına alınıp, saklanabilmekte ve işlenebilmektedir. Verilerin saklanıp işlenebilmesi önceki dönemlerde vakit alan ve maliyeti yüksek olan faaliyetler iken, mevcut teknoloji sayesinde, son derece hızlı ve düşük maliyetli hale gelmiştir. Günümüzde büyük miktarlardaki veriler veri madenciliği aracılığıyla analiz edilerek, geleceğe yönelik tahminlerde bulunmaya olanak sağlamaktadır. Alışveriş, bankacılık ve birçok farklı sektör, bünyesinde bulundurduğu çok sayıda veriyi analiz ederek şirketin büyümesi, geliştirilmesi veya olası risklerin tahmin edilerek önlem alınması gibi birçok konuda veri madenciliğinden yararlanmaktadırlar. Veri analizlerinden alınan sonuçlar doğrultusunda kurum ve kuruluşların ihtiyacına göre yol haritası oluşturulmaktadır. Böylelikle, işletmeler hem kullanıcı memnuniyeti konusunda iyileştirmeler

yapabilmekte hem de karlılıklarını arttırabilmekte veya olası zararlardan kaçınabilmektedirler.

Bu tez çalışmasında perakende sektöründe hizmet veren bir market işletmesinin müşteri bazında satışları incelenmiştir. Bu veriler ile, veri madenciliğinin temel uygulamalarından olan birliktelik kurallarından yararlanılarak pazar sepet analizi yapılmıştır. Analizler IBM SPSS Modeler veri madenciliği yazılımı ile gerçekleştirilmiş ve Apriori ve GRI birliktelik algoritmaları kullanılmıştır. Bu çalışmada müşterilerin Covid-19 öncesi ve sonrası alışveriş eğilimleri ortaya konulmuştur. Sonuç olarak Covid-19 öncesi ve sonrası gıda ürünlerinde farklılıklar görüldüğü ve pandemi döneminde müşterilerin eğilimlerinin değiştiği gözlemlenmiştir.

Anahtar Sözcükler : Pazar sepet analizi, birliktelik kuralları analizi, veri madenciliği, pandemi

Bilim Kodu : 90614

ABSTRACT

M. Sc. Thesis

DETERMINATION OF ASSOCIATION RULES WITH MARKET BASKET ANALYSIS: THE IMPACT OF COVID-19 ON THE RETAIL INDUSTRY

Ezgi ALANLAR

**Karabük University
Institute of Graduate Programs
Department of Industrial Engineering**

Thesis Advisor:

Prof. Dr. Filiz ERSÖZ

January 2021, 108 pages

Thanks to computer systems, large amounts of data can be recorded, stored, and processed. While storing and processing data was time-consuming and costly activities in the previous periods, it has become extremely fast and low cost with the developing technology. In today's world, large amounts of data are analyzed through data mining, which allows making predictions for the future. Shopping, banking, and many different sectors benefit from data mining in many areas such as the growth and development of the company or taking measures by predicting possible risks by analyzing the large number of data they contain. In line with the results obtained from data analysis, a road map is created according to the needs of institutions and organizations.

Hereby, businesses can both make improvements in user satisfaction and increase their profitability or avoid possible damages. In this thesis, 10-months sales of a company serving in the retail sector on a customer basis were examined. With these data, market basket analysis was performed by using association rules, one of the

basic applications of data mining. Analyzes were performed with IBM SPSS Modeler data mining software and Apriori and GRI association algorithms were used. In this study, the impact of the Covid-19 pandemic on consumer behavior has been investigated. Consequently, It has been examined that Covid-19 has impacted consumer behaviors during the pandemic period.

Key Word : Market basket analysis, association rules analysis, data mining, pandemic

Science Code : 90614

TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yűrűtűlmesinde ve oluőumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrűbelerinden yararlandığım, yűnlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ıőıęında őekillendiren sayın hocam Prof. Dr. Filiz ERSÖZ'e sonsuz teőekkűrlerimi sunarım.

Tez alıőması sűresince literatűr ve uygulama bűlűmlerinde deęerli yardımlarını esirgemeyen meslektaőlarım Oęuz Kılı, MBA ve Mira Potuk'a teőekkűr ederim.

Sevgili Annem, Babam ve Abim'e hibir yardımı esirgemeden her zaman yanımda oldukları iin tűm kalbimle teőekkűr ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER.....	ix
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ.....	xiv
SİMGELER VE KISALTMALAR DİZİNİ.....	xv
BÖLÜM 1.....	16
GİRİŞ.....	16
BÖLÜM 2.....	19
TÜKETİCİ SATIN ALMA DAVRANIŞLARI.....	19
2.1. PAZAR SEPETİ ANALİZLERİ.....	22
2.2. PANDEMİ DÖNEMİNDE TÜKETİCİ ALIŞVERİŞ EĞİLİMİ.....	22
BÖLÜM 3.....	27
VERİ, BİLGİ VE ENFORMASYON.....	27
3.1. VERİ TABANI SİSTEMLERİ VE VERİ AMBARI.....	28
3.1.1. Veri Tabanı Sistemleri.....	28
3.1.2. Veri Ambarı.....	29
3.1.3. Veri Tabanında Bilgi Keşfi.....	30
BÖLÜM 4.....	32
VERİ MADENCİLİĞİ.....	32
4.1. VERİ MADENCİLİĞİNİN TANIMI VE MAKİNE ÖĞRENİMİ.....	32
4.2. VERİ MADENCİLİĞİNİN UYGULAMA ALANLARI.....	33

	Sayfa
4.3. VERİ MADENCİLİĞİ SÜRECİ.....	35
4.4. VERİ MADENCİLİĞİ MODELLERİ.....	38
4.4.1. Tahmin Edici Modeller.....	39
4.4.2. Tanımlayıcı Modeller.....	39
4.5. VERİ MADENCİLİĞİ TEKNİKLERİ.....	39
4.5.1. Sınıflayıcı Modeller.....	39
4.5.1.1. Karar Ağaçları.....	40
4.5.1.2. Yapay Sinir Ağları.....	41
4.5.1.3. Bayes Sınıflandırma Algoritması.....	42
4.5.1.4. Naive-Bayes Algoritması.....	43
4.5.1.5. K-En Yakın Komşu.....	43
4.5.1.6. Genetik Algoritmalar.....	43
4.5.2. Regresyon Modelleri.....	44
4.5.3. Kümeleme.....	44
4.5.3.1. Hiyerarşik Kümeleme.....	45
4.5.3.2. K-Means (K-Ortalamlar) Tekniği.....	46
4.5.4. Birliktelik Kuralları.....	46
 BÖLÜM 5.....	 48
BİRLİKTELİK KURALLARI.....	48
5.1. BİRLİKTELİK KURALLARINDA SIK KULLANILAN ALGORİTMALAR.....	49
5.1.1. AIS Algoritması.....	49
5.1.2. SETM Algoritması.....	50
5.1.3. Apriori Algoritması.....	50
5.1.4. Apriori-TID Algoritması.....	51
5.1.5. GRI Algoritması.....	52
 BÖLÜM 6.....	 53
LİTERATÜR.....	53
 BÖLÜM 7.....	 59
YÖNTEM VE UYGULAMA.....	59

	<u>Sayfa</u>
7.1. PROBLEMİN TESPİTİ.....	59
7.2. TANIMLAYICI İSTATİSTİKLER.....	63
7.3. HİPOTEZ TEST BULGULARI.....	67
7.3.1. Normallik Testi.....	67
7.3.2. Mann Whitney U Testi.....	67
7.3.3. Pandemi Öncesi ve Pandemi Sonrası Yüzdesel Değişim.....	68
7.4. VERİ MADENCİLİĞİ BULGULARI.....	70
7.4.1. Uygulamada Kullanılan Teknolojiler.....	70
7.4.2. Veri Madenciliği Süreçleri.....	70
7.4.2.1. Veri Setinin Oluşturulması.....	70
7.4.2.2. Veri Setinin Temizlenmesi.....	71
7.4.2.3. Verilerin Dönüşüm Süreci.....	71
7.5. MARKET SEPET ANALİZİ UYGULAMASI.....	71
7.5.1. Apriori Algoritması ile Pandemi Öncesi Satışların Analizi.....	71
7.5.1.1. Model.....	71
7.5.1.2. Veri Madenciliği Sonuçları.....	72
7.5.1.3. Apriori Algoritması ile Bulunan Birliktelik Kuralları.....	75
7.5.2. Apriori Algoritması ile Pandemi Sonrası Satışların Analizi.....	76
7.5.2.1. Model.....	76
7.5.2.2. Veri Madenciliği Sonuçları.....	77
7.5.2.3. Bulgular.....	80
7.5.3. GRI Algoritması ile Pandemi Öncesi Satışların Analizi.....	81
7.5.3.1. Model.....	81
7.5.3.2. Veri Madenciliği Sonuçları.....	82
7.5.3.3. Bulgular.....	87
7.5.4. GRI Algoritması ile Pandemi Sonrası Satışların Analizi.....	88
7.5.4.1. Model.....	88
7.5.4.2. Veri Madenciliği Sonuçları.....	88
7.5.4.3. Bulgular.....	93
7.5.5. GRI Algoritması ve Apriori Algoritmasının Karşılaştırılması.....	93
BÖLÜM 8.....	97

	<u>Sayfa</u>
SONUÇLAR VE ÖNERİLER.....	97
KAYNAKLAR.....	100
ÖZGEÇMİŞ.....	108

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1. Veri madenciliği.....	16
Şekil 2.1. İngiltere ve ABD’deki tüketicilerin Covid-19 sonrası psikolojik durumu.20	
Şekil 2.2. 2012-2025 Yılları arasındaki yıllık gelir tablosu.....	23
Şekil 2.3. 2012 ve 2020 Yılı ürün gruplarına göre gelir tablosu.....	24
Şekil 2.4. Anket sonucuna göre ürün grubu bazında tüketim eğilimleri.....	26
Şekil 3.1. Veritabanı yönetim sistemleri.....	29
Şekil 3.2. Veri ambarı yapısı.....	30
Şekil 3.3. Veritabanlarında bilgi keşfi süreci.....	31
Şekil 4.1. CRISP-DM Süreci ve adımları.....	36
Şekil 4.2. Veri madenciliği modelleri.....	38
Şekil 4.3. Yapay sinir ağı yapısı.....	41
Şekil 4.4. Koordinat düzleminde kümeleme örneği.....	45
Şekil 5.1. Apriori akış diyagramı.....	51
Şekil 7.1. Pandemi öncesi ve sonrası alınan ürünler.....	66
Şekil 7.2. Apriori Algoritması ile IBM SPSS Modeler birliktelik kuralları modeli 1	72
Şekil 7.3. Apriori Algoritması ile IBM SPSS Modeler birliktelik kuralları modeli 2	76
Şekil 7.4. GRI Algoritması ile IBM SPSS Modeler birliktelik kuralları modeli 1	81
Şekil 7.5. GRI Algoritması ile IBM SPSS Modeler birliktelik kuralları modeli 2	88
Şekil 7.6. Apriori algoritması ve GRI algoritmasının sonuçlarının karşılaştırılması.95	

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 4.1. Veri madenciliğinin uygulama alanları.....	34
Çizelge 5.1. Birliktelik kural algoritmalarının karşılaştırması.....	51
Çizelge 7.1. Ham veri setinden bir bölümün ekran görüntüsü	60
Çizelge 7.2. Pandemi öncesi satılan ürünler.....	61
Çizelge 7.3. Pandemi sonrası satılan ürünler.....	62
Çizelge 7.4. Ana ürün grupları.....	63
Çizelge 7.5. Pandemi öncesi ve sonrası sepet alışveriş istatistikleri.....	64
Çizelge 7.6. Normallik testi.....	67
Çizelge 7.7. Mann-Whitney U test sonuçları.....	68
Çizelge 7.8. Pandemi öncesi ve sonrası yüzdesel değişim.....	68
Çizelge 7.9. Apriori algoritması ile pandemi öncesi bulunan birliktelik kuralları	73
Çizelge 7.10. Apriori algoritması ile pandemi sonrası bulunan birliktelik kuralları..	78
Çizelge 7.11. GRI algoritması ile pandemi öncesi bulunan birliktelik kuralları.....	83
Çizelge 7.12. GRI algoritması ile pandemi sonrası bulunan birliktelik kuralları.....	89
Çizelge 7.13. Apriori ve GRI algoritması sonuçlarının karşılaştırılması.....	94
Çizelge 7.14. Pandeminin perakende sektörüne etkileri.....	96

SİMGELER VE KISALTMALAR DİZİNİ


VT	: Veri Tabanı
CRM	: Customer Relationship Management (Müşteri İlişkileri Yönetimi)
OLAP	: On Line Analytical Processing
RDBMS	: Relational Database Management Systems (İlişkisel Veritabanı Yönetim Sistemleri)
VTBK	: Veri Tabanlarında Bilgi Keşfi
CRISP-DM	: Cross-Industry Standard Process for Data Mining (Veri Madenciliği için Çapraz Endüstri Standart Süreci)
S	: Support (Destek)
C	: Confidence (Güven)
IDE3	: Iterative Dichotomiser
CART	: Classification and Regression Trees (Sınıflandırma ve Regresyon Ağaçları)
CHAID	: Chi-Squared Automatic Interaction Detector
TID	: Transaction Identification
GRI	: The Generalized Rule Induction
WHO	: World Health Organization (Dünya Sağlık Örgütü)
ABD	: Amerika Birleşik Devletleri
VTYS	: Veri Tabanı Yönetim Sistemi
P.Ö.	: Pandemi Öncesi
P.S.	: Pandemi Sonrası

BÖLÜM 1

GİRİŞ

Günümüzde, teknoloji hayatımızın her alanına nüfuz etmiş durumdadır. Eski dönemlere oranla daha az maliyetli ve erişimi kolaydır. Bu durum birçok insanın hayatını kolaylaştırdığı gibi, çok fazla veri yığına sahip şirketlerin de ilgi odağı halindedir. Market, banka ve bunlar gibi çeşitli işletmeler veri yığınlarını ayıklamak, işlemek ve analiz edebilmek için veri madenciliği tekniklerinden faydalanmaktadır. Veri madenciliği, karmaşık ve fazla miktardaki verilerin işlenmesi, sınıflandırılması ve analiz edilmesiyle verilerin anlamlı hale getirilmesini sağlayan bilgisayar destekli sistem olarak tanımlanabilir.

Veri madenciliği faydalı olma potansiyeli olan bilgileri ortaya çıkararak, geleceğe yönelik tahminlerde bulunmaya yardımcı olur. Veri madenciliğinin ilk önceliği daha önce bulunmamış veri desenleri ve veriler arasındaki ilişkileri ortaya koymaktır. Bu ilişkiler sınıflayıcı, kümeleyici modeller ve birliktelik kuralları gibi veri madenciliği teknikleri ile çözümlenerek, geleceğe yönelik tahminlerde bulunma imkânı sunar.



Şekil 1.1. Veri madenciliği [1].

Teknolojideki gelişim, birçok sektörde rekabeti son derece arttırmış durumdadır. Rekabetteki artış, perakendeci kuruluşların sürekli iyileşmeye, özgün ve benzersiz olmaya daha fazla önem vermelerini sağlamıştır. Bu kuruluşların rakiplerinin önüne geçebilmeleri için yalnızca satılan ürünler veya ürünlerin fiyatları yeterli olmamakta, eş zamanlı olarak ürünlerin satışa sunulduğu ortamın özgünlüğü de büyük rol oynamaktadır. Bu durum, müşterilerin ilgili kuruluşa karşı sadakat göstererek, yeniden satın alma yapmaları konusunda da önemli bir etkidir [2].

Satış ortamının dikkat çekiciliği, büyük ölçüde mağaza içi raf dizilimi ile ilgilidir. Mağaza düzeni ve satışı yapılan ürünlerin konumlandırılış şekli doğrudan müşterinin mağaza içerisinde geçireceği süreyi ve satın alacağı ürün miktarını etkilemektedir. Tüketicilerin mağaza içerisinde geçirdiği süre ile satın alma ihtimalleri doğru orantılı olduğu bilimsel olarak kanıtlanmıştır. Buna bağlı olarak mağazadaki raf diziliminin şirketin kârlılığını doğrudan etkilediği söylenebilir. İyi analiz edilerek oluşturulmuş raf dizilimi, sadece mağazayı gezmek için gelmiş olan bir müşterinin alışveriş yaparak mağazadan ayrılmasını sağlayabilirken, özensiz yapılan raf dizilimi alışveriş yapmak için gelen bir müşterinin hiçbir şey almadan mağazadan ayrılmasına neden olabilmektedir [3]. Bu noktada, şirketlerin veritabanlarından elde edilen veriler ile birliktelik kurallarının bulunması ve sık olarak rastlanan olayların ortaya çıkarılarak müşterilerin satın alma eğilimlerinin saptanmasını sağlayan market sepet analizinden faydalanılmalıdır. Market sepet analizinde marketlerden alınan alışveriş verilerine göre analizler yapılarak, ürünlerin birlikte görülme olasılıklarından bulunan ilişki kuralları ortaya çıkarılır ve bu bulunan kurallar ile marketlerin satış stratejilerini iyileştirmelerine olanak sağlanmaktadır.

Bugünün koşullarında perakendecilik sektörü, istihdam sağlaması ve üretime olan katkısı nedeniyle ülke ekonomileri için son derece önemlidir. Bir ülke ekonomisinin gelişmişliğinde perakende sektörünün katkısı yadsınamazdır [4]. Perakende sektörü çeşitli satış kanallarını eş zamanlı ve aktif olarak kullanıp zamanla değişime uğrayan müşteri isteklerine net olarak cevap vermelidir. Bu yüzden yenilikçi teknolojiler ve yatırımlar büyük önem arz etmektedir [5].

Tüketici alışveriş eğilimleri kişisel faktörler yaş ve yaşam döngüsü, ekonomik alım gücü, hayata bakış açısı, kişisel ihtiyaç kavramları altında araştırılabilir [6]. Tüketicilerin dünyasına girebilmek ve o dünyada neler olduğunun farkına varmak rekabet üstünlüğünü beraberinde getirebilir [7].

Tüm dünyayı kısa sürede etkisi altına alan Covid-19 salgını, tüketicilerin satın alma eğilimlerini doğrudan etkilemiştir. Tüketiciler market ziyaretlerini azaltıp, çoğunlukla online alım yapmaya başlamışlardır. Bunun yanı sıra kuru gıda gibi temel besin maddelerini stoklamayı tercih etmişlerdir. Amerika Birleşik Devletleri'nin Şikago (İllinois) eyaletinde 2.040 tüketicinin katılımıyla yapılan araştırma sonuçlarına göre, tüketicilerin %68'i en çok harcamayı et alımı için yaptıklarını belirtmişlerdir. Bunu sırasıyla; %59 oranı ile temizlik ürünleri, %48 oranı ile süt ve yumurta, %45 oranı ile balık, %39 oranı ile kâğıt havlu ürünleri, %37 oranı ile meyve, %30 oranı ile bakliyat, %29 oranı ile peynirler ve %28 oranı ile tavuk ürünleri izlemiştir [8].

Amerika Birleşik Devletleri'nin Phoenix ve Detroit eyaletlerinde yapılan bir başka çalışmaya göre ise, sık sık market alışverişi yapan tüketicilerin %16 oranında bakliyat ve tahıl ürünleri, %8,9 oranında dondurulmuş gıda ve %8,2 oranında süt ve süt ürünleri tükettiği ortaya çıkmıştır. Stok tutan tüketicilerin ise, %9,7 oranında konserve, %9 oranında dondurulmuş gıda, %8,8 oranında et ürünleri ve %5,6 oranında süt ürünleri tükettiği sonucuna ulaşılmıştır [9]. Değişen bu satın alma eğilimine karşı strateji geliştirip, sürece hızlı uyum sağlayabilen işletmeler kalkınmaya devam edebilmektedir.

BÖLÜM 2

TÜKETİCİ SATIN ALMA DAVRANIŞLARI

Tüketim kavramı günümüz toplumlarının temel özelliği haline gelmiş olup, 20.yy. sonrası iktisadi bir kavram olmanın yanında kültürel, psikolojik ve sosyal bir kavram olarak da belirginleşmeye başlamıştır. Bunun sonucunda, tüketici satın alma davranışlarının incelenmesi ve analizi işletmeler için son derece önemli bir hâle gelmiştir. Tüketici satın alma davranışlarını etkileyen faktörlerden bazıları aşağıda açıklanmıştır.

Yaş: Tüketicinin satın alma eğilimini doğrudan etkileyen faktörlerdendir. Her yaşın kendine özgü gereksinimleri bulunmaktadır. Bu gereksinimler tüketicinin satın alma eğilimini doğrudan etkilemektedir. Örneğin, 15 yaşındaki bir tüketicinin market alışverişinde çikolata ve atıştırmalık gibi ürünler dikkatini çekecekken, 40 yaşındaki bir tüketici meyve, sebze gibi gıda ürünlerine ilgi gösterecektir [10].

Cinsiyet: Cinsiyet faktörü satın alınacak ürüne karar verilmesi ve ürün cinsinin belirlenmesi gibi durumlarda satın alma davranışına etki etmektedir [11].

Medeni Durum: Medeni durum tüketicinin satın alma eğilimini doğrudan etkileyen önemli faktörlerden biridir. Evli ve çocuk sahibi bir tüketici, kendisi dışında eşi ve çocuklarının taleplerini de göz önünde bulundurarak alışveriş yapacaktır. Bekâr olan bir tüketici ise, yalnızca kendi isteği doğrultusunda alışveriş yapmasının yanı sıra, yüksek ihtimalle evli ve çocuk sahibi olan bir tüketiciye göre çok daha az miktarda alım yapacaktır.

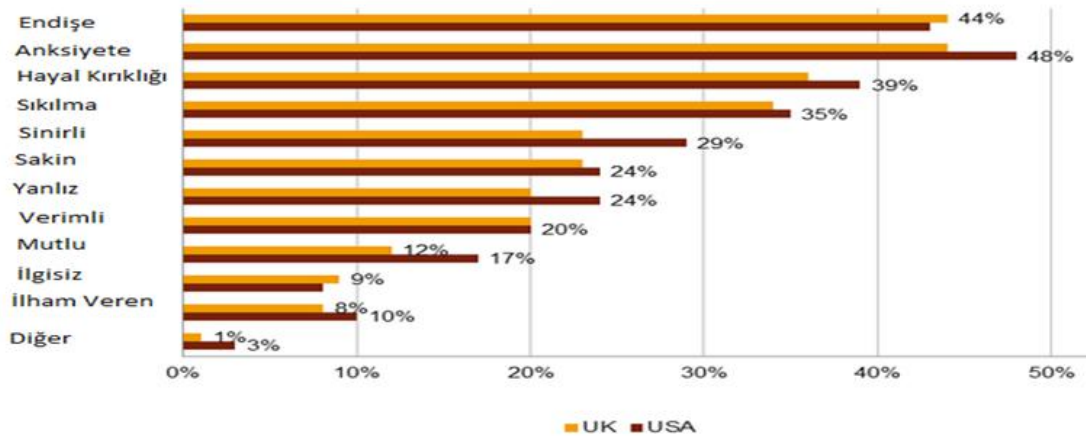
Kültür: Özellikle Amerika Birleşik Devletleri gibi çok fazla farklı milliyetten ve kültürden insanın bir arada yaşadığı ülkelerde kültürün satın alma eğilimine etkisi çok daha net bir şekilde gözlemlenebilmektedir. Örneğin, inancı gereği helal gıda

tüketen bir tüketici üründe helal ibaresi görmeyi isteyecektir. Bu ibarenin olmaması durumunda ürünü satın almayacaktır.

Sosyal Sınıf: Sosyal sınıfı belirleyen maddi kazanç, kültür, öğrenim düzeyi gibi birçok değişken bulunmaktadır. Gelir kaynağı kısıtlı olan bir tüketici uygun fiyatlı ürünleri tercih edecekken, kazancı çok iyi olan bir tüketicinin fiyat endişesi bir önceki örneğe göre daha düşük seviyede olacaktır [10].

Tüketici satın alma eğilimini etkileyen yukarıdaki faktörlerin beraberinde, Covid-19 pandemisi de tüketicilerde endişe ve kaygıya sebep olmuştur. Bununla birlikte, tüketici harcamalarında belirgin olarak düşüş görülmüştür. Bu yüzden tedarikçiler, satıcılar ve hizmet üreticileri ekonomik olarak negatif yönde etkilenmiştir. Pandemi hem tüketicileri hem de üreticileri gözle görülür bir şekilde etkilemiştir. Pazarlama ve ekonomi alanlarında çokça araştırma yapılmasına neden olmuştur. Bu çalışmalar pandemi süreci ile pandemi öncesi süreçleri kapsamaktadır [12].

İngiltere ve ABD'deki tüketicilerin Covid-19 sonrası psikolojik durumunun karşılaştırılması Şekil 2.1'de verilmiştir.



Şekil 2.1. İngiltere ve ABD'deki tüketicilerin Covid-19 sonrası psikolojik durumu [13].

Widjaja ve Chipeta (2020)'nın yaptığı araştırmaya göre İngilizler pandemi döneminde daha endişeli olma eğilimi gösterirken, Amerikalılar'ın daha mutlu ve sakin bir yapıya sahip olduğu görülmüştür. Tüketiciler virüse yakalanma konusunda endişeli olup, Covid-19 pandemisinin ekonomik etkileri konusunda da olumsuz fikirlere sahiptir [13].

Covid-19 pandemisinin başlaması ile dünya ülkelerinin ekonomilerinde talep dengesi bozulmuştur. Bu nedenle ekonomik durgunluk daha da derinden hissedilmiştir. Gıda, temizlik ve sağlık alanları başta olmak üzere temel ihtiyaç maddelerine olan talep artarken; eğlence ve sanat gibi alanlarda talep düşüşü belirgin şekilde görülmüştür [14].

Covid-19 pandemisi süresince internetten alışveriş yapma oranı artış göstermiştir. Pandemi boyunca özellikle Amerika Birleşik Devletleri'nde geniş çaplı faaliyet gösteren ve online alışveriş imkânı sunan Amazon, talepleri karşılayabilmek için çalışan sayısını artırmış ve tedarik zincirinde iyileştirmeye gitmiştir. Online satışlardan birçok firma büyük karlar elde etmiştir. Bunlardan biri olan Shopify, size hem çevrimiçi hemde çevrimdışı mağaza oluşturmanıza imkân veren bir e-ticaret platformudur. Amerika Birleşik Devletleri'ndeki bazı işletmeler pandemi dönemi süresince kira, elektrik gibi giderlerden muaf olabilmek için Shopify gibi çevrimiçi ve çevrimdışı hizmet verme imkânı sunan online uygulamalara yönelmişlerdir.

Amerika Birleşik Devletleri'nde yaygın olarak kullanılan Mercato ve Instacart gibi uygulamalar sayesinde perakende sektöründe hizmet veren işletmeler kendilerini tüketiciye tanıtmaya imkân bulmuştur. Bu sayede online alışverişlerin yanı sıra market ziyaretlerinde bulunan yeni müşteri sayısı da artış göstermiştir. Firmalar bu uygulamalar sayesinde müşterilerin sipariş geçmişlerinden oluşan büyük veriler elde ederek hangi ürünlerin yoğun olarak satın alındığını ve bu ürünlerin diğer ürünlerle birlikte görülme olasılıklarını analiz etme ve inceleme fırsatı bulmuştur.

2.1. PAZAR SEPETİ ANALİZLERİ

Ürün sepet analizi genelleştirilmiş öngörüsöl (predictive) yöntemler olarak da tanımlanmakta olup, belirli bir sonucu bir dizi kural ile ilişkilendirmeye çalışırlar. Sepet analizi birliktelik kuralları olarak da bilinmektedir. Olayların birlikte olma kurallarını belirli olasılıklarla ortaya koyar [15].

Pazar sepeti analizi, perakendeci işletmeler tarafından ürünler arasındaki ilişkileri ortaya çıkarmak için kullanılan temel tekniklerden biridir. İşlemlerde sık sık birlikte oluşan öge kombinasyonlarını arayarak çalışır. Başka bir deyişle, perakendecilerin, insanların satın aldığı ürünler arasındaki ilişkileri belirlemesine olanak tanır. İlişkilendirme kuralları, perakende alışveriş sepetini veya işlem verilerini analiz etmek için yaygın olarak kullanılır ve güçlü kurallar kavramına dayanan ilginçlik ölçütlerini kullanarak işlem verilerinde keşfedilen güçlü kuralları belirlemeyi amaçlar [16]. Pazar sepet analizi ile; birlikte görülen ürünlerin olasılıklarından yararlanılarak; market raf düzenlerini optimize etmek, ürün paketleri tasarlamak, hangi ürünlerin birlikte satın alınabileceğinin anlaşılmasına yardımcı olmak, kupon tekliflerini planlamak, uygun özel ürünleri seçmek ve doğrudan pazarlamada etkili olan ürünleri ortaya çıkarmak için kullanılır. Pazar Sepeti Analizi “If-Then” senaryosu kurallarını oluşturur; örneğın, eğer A maddesi satın alınırsa, B maddesinin satın alınması muhtemeldir.


2.2. PANDEMİ DÖNEMİNDE TÜKETİCİ ALIŞVERİŞ EĞİLİMİ

İnsanlık tarihinde meydana gelmiş olan salgınların sonucunda iktisadi ve politik olarak köklü deęişiklikler yaşandıęı bilinmektedir. Tarihte daha önce olduęu gibi, 31 Aralık 2019 tarihinde ilk olarak Çin’de görülen Covid-19 salgını da tüm dünyayı hızla etkisi altına almış ve toplumlari sosyal, ekonomik ve siyasi olmak üzere her yönüyle derinden etkilemiştir. Dünya genelinde yaklaşık 200 ülke ve bölgeye yayılması sonucu küresel pandemi haline gelen korona virüsü, tespit edilen ilk vakadan bugüne tüm dünyada yaklaşık 94 milyon 125 milyon kişiye bulaşırken, 2 milyon 35 bin kişinin ise ölümüne neden olmuştur [17]. Çin üzerinden sürekli artarak yayılan virüs, Avrupa’dan sonra Amerika Birleşik Devletleri’nde en yüksek vaka

sayısına ulaşılmasına neden olmuştur. Şu an hâlâ 23 milyon 556 bin adet Covid-19 vakası ile Amerika Birleşik Devletleri en çok vakanın görüldüğü ülke olarak birinci sırada yer almaktadır.

Devletler tarafından getirilen seyahat, eğitim, kültürel alanlardaki kısıtlamalar ekonomi ve sosyal hayatı doğrudan etkilediği gibi, tüketicilerin alışveriş eğilimlerini de değiştirmiştir. Evde daha çok zaman geçirmeye başlayan tüketiciler temizlik, kişisel bakım ürünleri ve kuru gıdaların alımını arttırmaya yönelmiştir [18].

Statista isimli araştırma şirketinin Ocak 2021’de güncellenen raporuna göre; Amerika Birleşik Devletleri’nde gıda sektörünün 2012 ve 2020 yılları arasında meydana gelen yıllık gelir değişimleri ile 2021 ve 2025 yılları arasındaki yıllık gelir tahminleri şekil 2.2’de verilmiştir.



Şekil 2.2. 2012-2025 Yılları arasındaki yıllık gelir tablosu [19].

Yapılan tahminlere göre 2021 yılında gıda sektöründeki toplam satış gelirinin 2020 yılına göre %0,88 oranında düşüş göstermesi beklenmektedir.

Amerika Birleşik Devletleri’nde 2012 ve 2020 yıllarındaki yıllık gelir tablosu ürün grubu bazında Şekil 2.3’te verilmiştir.

2012 Yılı Gelir Tablosu		2020 Yılı Gelir Tablosu	
■ Süt Ürünleri ve Yumurta	US\$68,632.3m	■ Süt Ürünleri ve Yumurta	US\$89,434.3m
■ Et ve Et Ürünleri	US\$118,669.3m	■ Et ve Et Ürünleri	US\$157,492.2m
■ Deniz Ürünleri ve Balık	US\$21,236.5m	■ Balık ve Deniz Ürünleri	US\$28,408.9m
■ Meyveler ve Çerezler	US\$61,107.7m	■ Meyveler ve Çerezler	US\$81,700.5m
■ Sebzeler	US\$62,876.9m	■ Sebzeler	US\$83,968.2m
■ Unlu Mamüller	US\$53,875.5m	■ Unlu Mamüller	US\$70,867.1m
■ Yağlar	US\$12,461.2m	■ Yağlar	US\$15,973.5m
■ Soslar ve Baharatlar	US\$21,997.0m	■ Soslar ve Baharatlar	US\$27,663.4m
■ Hazır Gıda	US\$36,482.5m	■ Hazır Gıda	US\$54,705.2m
■ Reçeller ve Tatlandırıcılar	US\$8,766.6m	■ Reçeller ve Tatlandırıcılar	US\$10,227.8m
■ Şekerlemeler	US\$226,294.8m	■ Şekerlemeler	US\$300,111.3m

Şekil 2.3. 2012 ve 2020 Yılı ürün gruplarına göre gelir tablosu [19].

Ürün grubu bazında 2012 yılı ile 2020 yılı arasındaki gelir değişimleri karşılaştırıldığında süt ürünleri ve yumurta grubunda %30; et ürünlerinde %32; deniz ürünlerinde %33; meyve ve çerez grubunda %33; sebzelerde %33; unlu mamüllerde %31; yağlarda %28; sos ve baharat grubunda %25; hazır gıdada %50; reçel ve tatlandırıcılarda %16; şekerleme grubunda ise %32 artış görülmektedir. Sekiz yıllık bu süre içerisinde en fazla talep olan ürün grubu hazır gıdalar olurken, en az talep gören ürün grubu ise reçel ve tatlandırıcılar olmuştur.

Knotek vd. Mart ve Nisan 2020 ayları arasında, Amerika Birleşik Devletleri'nde Covid-19 hızla yayılırken, pandeminin ekonomi üzerindeki etkileri hakkında tüketicilerin düşüncelerinde belirgin bir değişiklik olduğunu ileri sürmektedirler. Tüketicilerin, Covid-19'un GSYİH tarafından tespit edilen ekonomik faaliyet üzerinde önceden tahmin ettiğinden daha fazla negatif etkiye sahip olmasını beklediklerini; eş zamanlı olarak, tüketiciler Covid-19'un enflasyonun yukarı yönde artmasını beklediklerini belirtmektedirler. Yürütülen çalışmada, tüketicilerin planlanan büyük ölçekli satın alımları ötelediklerini, finansal planlamalarını yenilediklerini veya işlerini kaybedeceklerinden endişe ettiklerini bildiren ifadelerin bulunduğunu ileri sürmektedirler. Araştırmaya katılanların %50'den çoğu 10 Mart'ta, Covid-19 pandemisinin 6 aydan daha kısa süreceğini düşünürken; zamanla, görüşlerinin pandeminin daha uzun sürebileceği yönünde değiştiği gözlemlenmiştir.

Son durumda, katılımcıların yalnızca üçte biri pandeminin 6 aydan kısa süreceğini düşünürken, diğer üçte ikisi bir yıl veya daha fazla süreceğini düşünmektedir. Bu süre zarfında tüketicilerin satın alma alışkanlıklarının gıda ve tıbbi malzeme stoklarına yönelik olduğu belirtilmektedir [20]. Diğer bir deyişle tüketicilerin temel ihtiyaçlarını karşılayan (gıda, sağlık) ürünlere yöneldikleri söylenebilir.

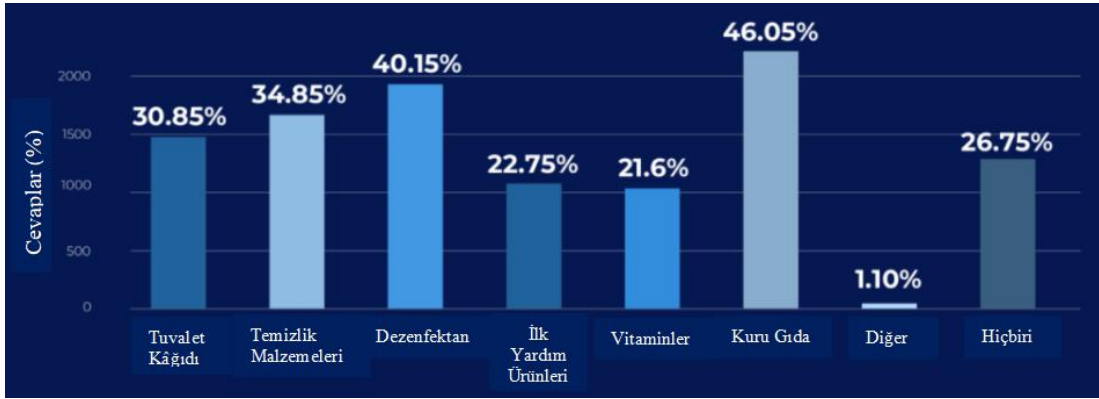
Nielsen Araştırma Şirketi, yaptığı çalışma sonucunda salgın döneminde tüketicilerin temel ihtiyaçlara yöneldiği hipotezini destekleyen sonuçlara ulaşmıştır. Bu çalışmaya göre, karantina ve sokağa çıkma yasakları sebebiyle tüketicilerin evlerinde kalmalarının, tüketicilerin sosyal faaliyetlerini ciddi derecede azalttığını, tüketicilerin yalnızca temel ihtiyaçlarını karşılamaya yönelik aktivitelerde bulunduğunu göstermektedir. Tüketicilerin dışarı çıkmaları için en belirgin nedenleri sağlık, gıda tedariki veya banka faaliyetleridir [21].

Salgın döneminde birçok kişi endişe ve kaygı yaşamıştır. Bu durum hane halkı tüketim alışkanlıklarını da doğrudan etkilemiştir. İngiltere’de yapılan bir çalışmaya göre Covid-19’un başlangıç dönemi ve sonraki dönemine yönelik ortalama hane halkı harcamalarının gözlemlenmiş olup, hane halkı gelirlerinin büyük bir bölümünün pandemi döneminde market harcamaları ve kira giderlerine ayrıldığı, dışarıda yemek yemeye ise daha az bütçe ayrıldığı sonucu elde edilmiştir [22].

Yapılan araştırma sonucunda, ABD’de pirinç, un, konserve sebze ve bakliyatların (+% 433) ocak ve mart aylarındaki satışları karşılaştırılmış olup, bu aylar arasında kuru gıda satın alımlarında ciddi oranda artış olduğu sonucu elde edilmiştir [23]. İngiltere’de kutu süt satın alımları önceki haftalara göre normalden 3,5 kat daha fazla artış göstermiş olup, konserve meyve satın alımlarında 3 kat, un satın alımlarında ise 6 kata kadar artış olmuştur [23]. İngiltere, Amerika, Almanya ve Çin’de 2933 kişinin katılımıyla yürütülen farklı bir araştırmada ise, müşterilerin yiyecek ve içecek tüketimlerinin Çin’de %43, Almanya’da %22, İngiltere’de %27 ve Amerika’da %27 oranında artış gösterdiği anlaşılmıştır [24]. Ipsos Hane Tüketim Paneli’nin Türkiye’de gerçekleştirdiği araştırmaya göre ise, okulların tatil olması ile beraber; makarna, bakliyat, un, kolonya, sirke, süt, çikolatalı ürünler, çöp torbası gibi ürünlerin satın alımında artış yaşanmıştır [25]. Amerika’da gerçekleştirilen bir başka

arařtırmada, alımı en fazla artan ürünler sırasıyla; süt ve süt ürünleri, konserve yiyecekler ve pirinç olmuřtur [24].

17 Mart 2020 tarihinde 14-73 yaşları arasındaki 2.000 adet tüketiciye hangi ürünleri normalden daha fazla tükettikleri sorulmuřtur. Ankete katılanların; %34'ü ABD'de, % 34'ü Birleşik Krallık'ta ve % 33'ü Kanada'da yaşamaktadır. Katılımcıların %30,85'i tuvalet kâğıdı, %34,85'i temizlik malzemeleri, %40,15'i dezenfektan, %22,75'i ilk yardım ürünleri, %21,6'sı vitaminler ve %46,05'i kuru gıda tüketiminde artış olduğunu belirtmiştir. 26,75% oranındaki katılımcılar ise tüketim eğilimlerinde bir deęişiklik olmadığını belirtmiştir [26]. Anket sonucuna göre ürün grubu bazında tüketim eğilimleri Şekil 2.4'te verilmiştir.



Şekil 2.4. Anket sonucuna göre ürün grubu bazında tüketim eğilimleri [26].

Tüketicilerin e-posta, SMS, sosyal medya ve daha fazlası dahil olmak üzere pazarlama mesajlarına daha duyarlı olmasıyla birlikte, alışveriş davranışı gelişmeye başlamaktadır.

Tüketiciler, her şeyden önce yiyecek satın almaya, aynı zamanda gıda takviyeleri, termometre ve ilaç gibi öğeler dahil olmak üzere sağlığı ve zindelięi teşvik eden ürünleri satın almaya öncelik verdiği gözlenmektedir. Ürünler mağazalarda stokta kalmadıysa, tüketiciler daha az tanıdık markaları da deęerlendirdikleri gözlenmiştir.

BÖLÜM 3

VERİ, BİLGİ VE ENFORMASYON

Gündelik hayatta bilgi ve veri terimleri aynı anlama gelen kavramlar olarak kullanılıyor olsa da dağınık halde bulunan çeşitli verilerin düzenlenerek bilgiye dönüştürülebildiği bilinmektedir. İşlenmemiş, düzenlenmemiş veri tek başına anlamsızdır. Bir örnek ile açıklanacak olursa, “10” sayısı bir mağazadaki ürünün adedini, müşteri alışverişinin toplam tutarını veya müşterinin bulunduğu sıralamadaki yerini temsil edebilir. Tek başına “10” sayısı net bir bilgi ifade etmez. Bir hedefe ulaşma amacıyla işlemde geçirilen veriye bilgi denir. Sorgulanan bir olaya veya sürece karşılık verebilecek şekilde veriden yapılan çıkarımlar bilgi olarak isimlendirilebilir [27]. Bu süreç veri analizi olarak adlandırılır. Enformasyon ise, verilerin belirli bir amaca yönelik bilgi süzgecinden geçirilerek anlamlandırılmasıdır. Enformasyonun yorumlanması ve tecrübe ile harmanlanması gerekmektedir.

Brown ve Duguid (2001) bilgi ile enformasyon arasındaki farkı: “Enformasyon, insanların derlediği, sahip olduğu, aktardığı, bir veri tabanına koyduğu, bulduğu, kaydettiği, biriktirdiği, saydığı, kıyasladığı vs. bir şeydir. Buna karşılık bilgi, sevkiyat, teslimat ve sayım gibi kavramlara pek uygun düşmez. Bilgiyi toplamak ya da transfer etmek zordur. Sözelimi birinden sahip olduğu enformasyonu size göndermesini ya da göstermesini isteyebilirsiniz; ama aynı şeyi bilgi için yapamazsınız” şeklinde belirtmektedir [28].

Büyük veri, sürekli kayıt alınan, farklı kaynaklardan elde edilen tüm verilerin anlamlı ve işlenebilir hale dönüştürülmüş halidir. Bir başka tanıma göre, “büyük veri, sadece bir sunucuya sığmayacak kadar büyük; satır ve sütun şeklinde yapılandırılmamış veridir [29].

Büyük veriler sayesinde sağlık kuruluşları hastalarına yönelik kişisel bilgileri depolayarak hastanın ne zaman kontrole gelmesi gerektiğini belirleyebilmektedirler. İlaç depolarında ilaçların tam olarak nerede ve ne zamandan beri saklandığı bilgisine daha kolay bir şekilde ulaşılabilir.

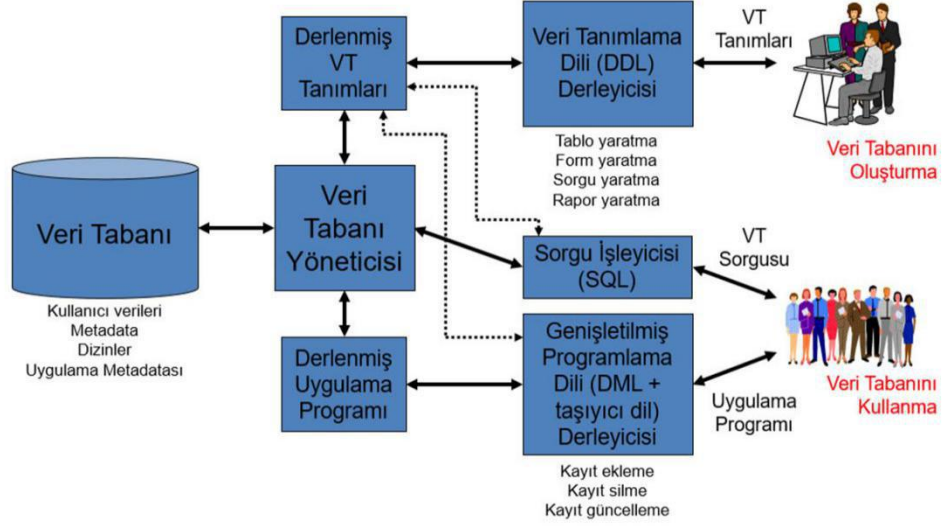
Perakende sektöründe ise, yapılan satışların analiz edilmesiyle hangi üründen ne kadar satış yapıldığı, bu satışın hangi tarih ve zaman aralığında gerçekleştirildiği ve hangi ürünlerin birlikte satıldığı gibi bilgilere ulaşılabilir. Elde edilen bu bilgiler sayesinde tedarikçiden yeterli miktarda satın alma işlemi gerçekleştirilerek stok maliyetleri indirgenebilir. Bununla birlikte, son kullanma tarihi geçen ürün sayısı düşürülerek, gerektiğinde son kullanma tarihi yaklaşan ürünler için promosyon uygulanabilmekte ve ürün ziyarı önlenebilir. Ayrıca, birlikte satılan ürünlerin tespit edilmesiyle işletme içerisinde raf dizilimi yeniden yapılandırılarak, satış miktarları artırılabilir. Verilerin bu şekilde analiz edilmesi müşteri sadakatini arttırmada önemli bir role sahiptir.

3.1. VERİ TABANI SİSTEMLERİ VE VERİ AMBARI

3.1.1. Veri Tabanı Sistemleri

Veri tabanı (Database), herhangi bir alanda birbirleri ile ilişki içerisinde olan verilerin sistematik olarak bir araya gelmesiyle oluşan yapılardır [30]. Bu yapılar yönetilebilir, depolanabilir ve analiz edilebilir olmalarıyla şirketlerin karlılıklarını arttırmada önemli bir araç olarak kullanılmaktadır. Veri yığınları ile veritabanlarının oluşturulması, depolanması, artırılması, yenilenmesi ve yönetilmesi için kullanılan uygulamalara Veritabanı Yönetim Sistemleri denir [31].

Veri tabanı yönetim sistemlerine ilişkin süreç Şekil 3.1’de verilmiştir.



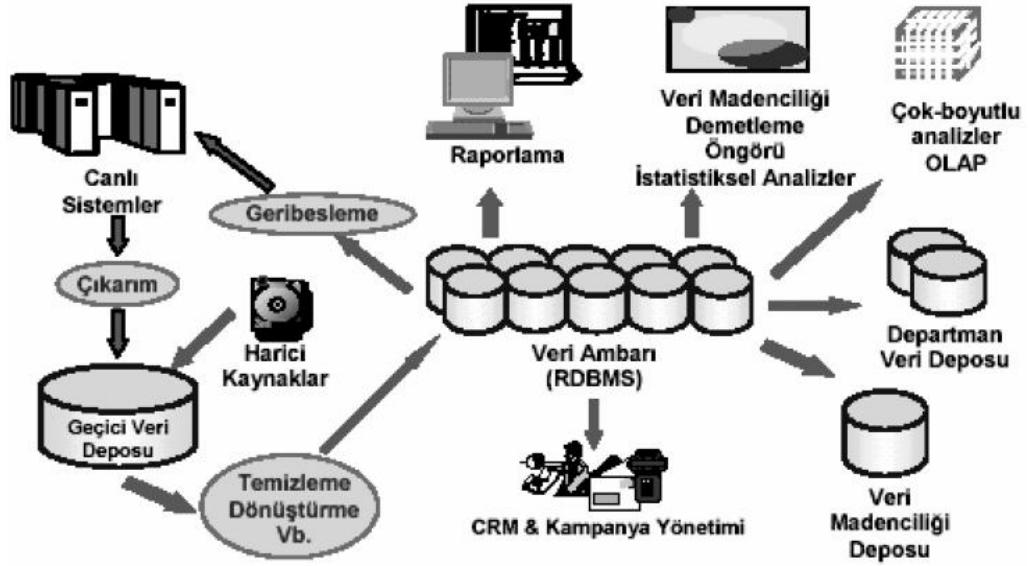
Şekil 3.1. Veritabanı yönetim sistemleri [32].

Veri Tanımlama Dili (VTD): Veri tabanı tanımlarını VTYS'ye aktarmak için kullanılan dile verilen isimdir.

3.1.2. Veri Ambarı

Veri ambarı şirketlerin veya organizasyonların karar vermesinde etkili olan entegre edilebilir, zamana göre değişkenlik gösteren ve konu odalı karar destek sistemleridir. Elde bulunan ham veri ve bilgiler farklı kaynaklardan elde edilmekte olup, veri ambarları bu verinin üzerinde inceleme ve sorgulama yapımını daha hızlı ve kolay bir şekilde gerçekleştirebilmektedir.

Veri ambarı yapısına ilişkin görsel Şekil 3.2’de verilmiştir.



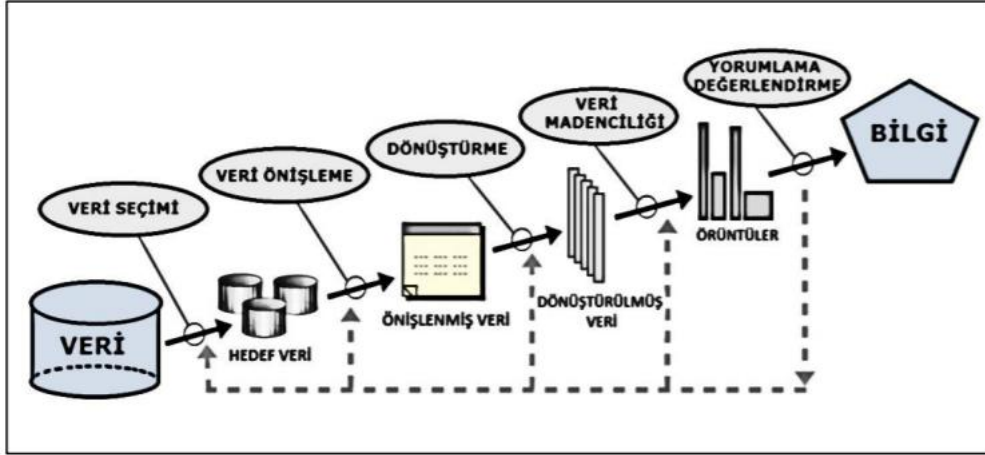
Şekil 3.2. Veri ambarı yapısı [33].

Veri ambarlarının maliyetli yatırımlar olmasının yanında, birçok sektör elde edeceği faydanın daha yüksek olduğunu bilerek gerekli yatırımları yapmaktadır.

3.1.3. Veri Tabanında Bilgi Keşfi

Veri madenciliği ile veri tabanında bilgi keşfi kavramları genellikle benzer kavramlar olarak düşünülmekte ve birbirinden farklı olmayan anlamlarda kullanılmaktadır. Ancak veri madenciliği bilinenin aksine bilgi keşfi sürecinin yalnızca bir süreci, aşamasıdır. Veri tabanında bilgi keşfi mevcut veride bulunan özgün, yararlı ve anlamlı olan değerli örüntüleri meydana çıkarma sürecidir [34].

Veri tabanlarında bilgi keşfi süreci şekil 3.3'te belirtilmiştir.



Şekil 3.3. Veri tabanlarında bilgi keşfi süreci [34].

Veri tabanı sistemlerinin zaman içerisinde yaygınlaşması ile elde oluşan veri yığınlarının nasıl verimli bir şekilde değerlendirilebileceği araştırma konusu olmuştur. Bu aşamada eskiden kullanılan manuel yöntemlerden ziyade veri tabanlarında bilgi keşfi (VTBK) adı altında araştırmalar yapılmaktadır. Veri tabanlarında bilgi keşfi süreci problemin tanımlanması, verilerin hazırlanması, modelin kurulması ve değerlendirilmesi, modelin kullanılması ve modelin izlenmesi ana başlıklarından oluşmaktadır [35].

BÖLÜM 4

VERİ MADENCİLİĞİ

4.1. VERİ MADENCİLİĞİNİN TANIMI VE MAKİNE ÖĞRENİMİ

Veri madenciliğini kısaca, atıl durumda olan veriden anlamlı ve fayda sağlayan bir veri ortaya çıkarma işlemi olarak tanımlayabiliriz. Bir diğer deyişle, verilerin içerisinde bulunan örüntü, desen ve birlikteliklerin ortaya çıkarılmasıdır [36].

Teknolojideki gelişim, veri tabanlarında günde yüzlerce, binlerce veri oluşumunu beraberinde getirmiştir. Veri miktarı arttıkça şirketlerin bu verileri değerlendirme planları daha karmaşık hale gelebilmektedir. Veri madenciliği bu karmaşıklığı ortadan kaldırarak bilgiye ulaşımı daha hızlı ve kolay bir hale getirir [37].

Bu tanımlardan yola çıkarak veri madenciliğinin temel amacı saklı veri setlerinin, analiz yapılmasına elverişli duruma getirilerek, ulaşılmak istenen bilgiye uygun olan tekniklerden faydalanılıp kısa sürede en doğru sonucun elde edilmesidir diyebiliriz.

Teknolojinin günümüzdeki kadar yaygın kullanılmadığı dönemde marketlerden alışveriş yapan müşterinin aldığı ürünlerin yalnızca toplam tutarı hesaplanabilmekteydi. Ancak barkod sistemlerinin geliştirilmesiyle birlikte, alışveriş için gelen müşterilerin alışveriş sonucunda ödeyecekleri tutarların yanı sıra, müşterinin hangi zaman aralığında alışveriş için markete geldiği, hangi tip ürünleri almaya daha eğilimli olduğu gibi birçok bilgiye ulaşılabilmektedir. Bu sayede, işletmeler raf dizilimlerini yenileyerek, ürün portföylerini güncelleyerek ve çeşitli promosyonlar oluşturarak kârlılık oranlarını çok daha kolay ve hızlı bir biçimde arttırabilmektedirler. Müşteri tarafından bakıldığında ise, alışveriş yaptıkları marketin kendi istekleri doğrultusunda şekillenmesi büyük bir memnuniyet ve markete karşı sadakat duygusu oluşturmaktadır.

Veri madenciliği uygulamalarının kullanımı için çeşitli bilgisayar yazılımlarından faydalanılmaktadır. Bu yazılımların bir kısmı ticari, bir kısmı ise kullanıcıların ücretsiz olarak yararlanabileceği açık kaynaklardır. Ticari olan yazılımlardan bazıları IBM SPSS Modeler (Clementine), IBM SPSS Statistics, SAS, Excel, Angoss, KXEN, SQL Server, MATLAB ve Oracle'dir. RapidMiner, WEKA, R, C4.5, Orange ve KNIME ise açık kaynaklardır [38].

Veri madenciliği uygulamaları kullanılırken hangi yazılımın kullanılması gerektiğinin anlaşılması için ilgili yazılımdan hem büyük hem de küçük veri setleri için anlamlı sonuç elde edilebilmesi, doğru tahminlerde bulunabilmesi ve görülemeyecek kadar küçük ve detaylı örüntüleri kullanıcıya kolayca gösterebilme özelliğine sahip olması beklenmektedir [39].

4.2. VERİ MADENCİLİĞİNİN UYGULAMA ALANLARI

Veri madenciliği sağlık, emlak, perakende, eğitim, bankacılık gibi çeşitli sektörlerde kullanılmaktadır. Veri madenciliği uygulaması herhangi bir meslek kolu veya alanı ayırt etmeksizin, fazla miktarda veriye sahip olan ve bu verilerin işlenmesine imkân sağlayan tüm alanlarda kullanılabilir [40]. Bugünün şartlarında faydalanılan veri madenciliği uygulamaları sayesinde çok fazla miktardaki veriler hızlı ve basit bir şekilde analiz edilerek, rapor oluşturulabilmektedir. Bu raporların yoğun olarak kullanıldığı pazarlama ve perakendecilik sektöründe yeni müşteriler kazanma ve mevcutta bulunan müşterinin korunması amaçlanmıştır. Bu alanlarda veri madenciliği uygulamalarından müşteri özelliklerinin belirlenmesi, müşterinin firma ile olan ilişkisinin takibi, rakip firmaya yönelebilecek müşterilerin tespit edilmesi ve firma yetkililerinin karar vermesi konularında faydalanılmaktadır [41]. Veri madenciliğinin uygulama alanlarından bazıları Çizelge 4.1'de gösterilmiştir.

Çizelge 4.1. Veri madenciliğinin uygulama alanları.

Kullanım Alanları	Kullanım Amaçları
Pazarlama	Market Sepet Analizi
	Satış Tahmini
	Çapraz Satış
	Müşteri Analizi
Bankacılık ve Sigortacılık	Kredi Talep Değerlendirmesi
	Riskli Müşterilerin Belirlenmesi
	Kredi Kartı Bilgi Hırsızlığının Tespitinde
Borsa	Piyasa Analizi
	Alım-Satım Stratejilerinin Belirlenmesi
Telekomünikasyon	Mobil Müşteri Analizi
Perakendecilik Sektörü	Satış Noktası Veri Analizi
	Alışveriş Sepeti Analizi
	Alım Stratejisi Belirleme
	Raf Düzeni ve Mağaza Yerleşimi Belirleme
	Promosyon Stratejisi Belirleme
Sağlık ve İlaç	İlaç Etkilerinin Bölgesel Analizi
	Tedavi Sürecinin Belirlenmesi
Endüstri	Kalite Kontrol Tespitinde
Bilim ve Mühendislik	Hücre Analizi
	Uzay Analizi

Pazarlama ve perakendecilik alanlarında önemli bir konuma sahip olan müşteri ilişkileri yönetimi, müşteri odaklı stratejiler oluşturmaktadır. Bu stratejiler müşterilerin tüketim eğilimlerini takip eden ve bu eğilimler ile ilgili veri tabanı oluşturan, firma ile müşteri arasında iletişim ağı kuracak teknolojik özelliklere sahiptir [42]. Bu sayede müşteriler hakkında farklı kanallardan veri ve enformasyon sağlanabilmektedir. Veri madenciliği uygulamaları yardımıyla elde bulunan verilerden anlamlı örüntüler oluşturularak müşteri profilleri elde edilmekte ve her müşterinin özelliklerine özgü ürün veya hizmet sunulabilmektedir [43]. Bunun yanı

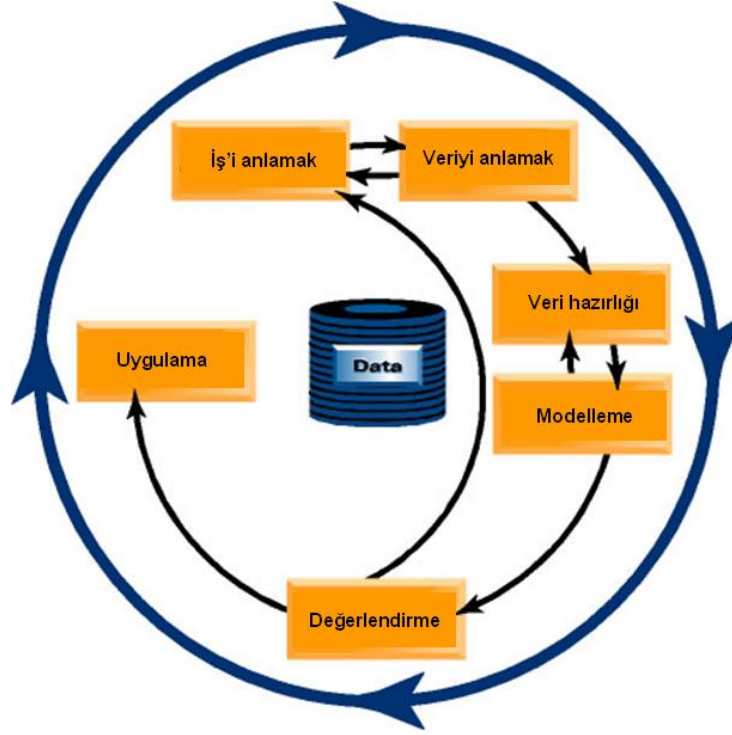
sıra, kümeleme ve sınıflandırma gibi veri madenciliği yöntemlerinden faydalanılarak ortak özellikler sergileyen müşteri grupları ortaya çıkarılıp, buna göre müşteri ilişkileri stratejileri geliştirilebilmektedir [44]. Bu stratejiler, hedef pazar oluşturulması, çapraz satış tekniği ile ürünler arasındaki ilişkilerin belirlenmesiyle raf sisteminin bu aynı doğrultuda düzenlenmesi, tüketici alışveriş eğiliminin tespit edilmesiyle ürün çeşidinin gözden geçirilmesi şeklinde sıralanabilir.

Veri madenciliği uygulamalarından finans alanında da faydalanılmaktadır. Bankalar bu uygulamalar yardımıyla müşteri kaybı analizi yaparak sonraki altı ay süresince müşteri kaybı olup olmayacağını öngörebilmektedir. Bu sayede bankalar müşteri özelinde kampanyalar oluşturarak müşteri sadakatini kazanmaya çalışabilmektedirler [45]. Bankacılık sektöründe yaygın olarak kullanılan kredi puanlama yöntemlerinden olan davranışsal puanlama analizi ile müşterilerin önceki dönemlere ait tüketim eğilimleri incelenerek gelecekteki tüketim eğilimleri öngörülebilmektedir. Ağırlıklı olarak gıda alımı yapan bir müşteriye gıda ürünleri satan işletmelerde geçerli olan kampanya bilgilerinin gönderilmesi ile müşterinin daha çok harcama yapması sağlanabilir [46]. Tıp alanında ise, veri madenciliği uygulamalarından faydalanılarak bir ilacın hangi yaş aralığındaki hastalarda daha etkili olacağı, kanser hastalığının tedavisinde en iyi tedavi yönteminin ne olacağı gibi konularda öngörüle bulunabilmektedir [47].

4.3. VERİ MADENCİLİĞİ SÜRECİ

Veri madenciliğinde genel olarak ‘Endüstriler Arası Standart İşleme Süreci’ anlamına gelen CRISP-DM (Cross-Industry Standard Process for Data Mining) prosesi uygulanmaktadır. CRISP-DM, bir kurumun sorunu, verilerinin bir araya getirilmesi, bu verilerden bir model oluşturulması ve gerekli analizin yapılarak düzenlenmesi aşamalarının tümünü içeren veri madenciliği prosesidir [48]. CRISP-DM prosesi işi anlama, verileri anlama, veri ön işleme aşaması, modelleme, değerlendirme ve uygulama olmak üzere altı aşamadan meydana gelmektedir. Belirtilen maddeler detaylı olarak açıklanacaktır.

CRISP-DM Süreci ve adımları şekil 4.1’de verilmiştir.



Şekil 4.1. CRISP-DM Süreci ve adımları [48].

İşi Anlama: CRISP-DM sürecinin bu ilk aşamasında temel amaç sorunun tam olarak ne olduğunu ve neden kaynaklandığını anlamaktır. Bir başka deyişle, sorunun tanımının yapılması ve çözüme giden yoldaki amacın net ve kesin olarak belirlenmesidir. Örneğin, bir işletme stokta bekleyen ürün miktarının çok fazla olması ile ilgili problem yaşıyorsa, ileriki dönemde hangi ürünlerde promosyon uygulanması gerektiği üzerinde çalışılabilir.

İşi anlama aşamasında hedefe ulaşabilmek için başlangıç planı yapılır. Bu aşama planının temelini oluşturduğu için veri madenciliğinin en önemli aşamalarından biri olduğunu söyleyebiliriz. Problemin doğru anlaşılması sonucu elde olan veriler gereksiz yere işlenebilir. Bu durum da zaman ve iş gücü kaybına neden olabilir.

Verileri Anlama: İkinci adım olan bu aşamada mevcut sorunu çözmeye gerekli olacak verilerin toplanması ve elde bulunan verinin kontrol edilerek kullanıma uygun olup olmadığına karar verilmelidir. Eğer var ise, veride bulunan hataların veya

sorunların belirlenmesi işlemi yapılır. Bu verilerin nasıl daha kullanışlı hale getirilebileceği üzerinde çalışılır.

Veri Ön İşleme Aşaması: Bu aşamada, toplanan veriler üzerinde hangi yöntemler uygulanacağına karar verilir ve verilerin tamamı en baştan itibaren tekrar düzenlenerek kontrol edilir. Gereksiz veya hatalı olan veriler temizlenir. Eğer gerekirse veri setini zenginleştirebilecek ilaveler yapılabilir. Bu aşamada düzenlenen veriler bir sonraki aşamalarda direkt olarak kullanılabilir duruma getirilmiş olmalıdır. Bu sebeple veri ön işleme aşamasının, veri madenciliğinin en çok zaman alan ve dikkat gerektiren bölümü olduğu söylenebilir.

Modelleme: Çeşitli modelleme tekniklerin belirlendiği ve uygulandığı bu aşamada sorun çözümünde en etkili olabilecek model seçimi yapılır. Gerekirse, sorun çözümüne yönelik modelde iyileştirmeler yapılabilir. Yapılan bu iyileştirmeler sonucunda hala istenen modelin elde edilememesi durumunda veri ön işleme aşamasına geri dönülerek verileri kullanıma elverişli hale getirebilmek için yeniden çalışma yapılır.

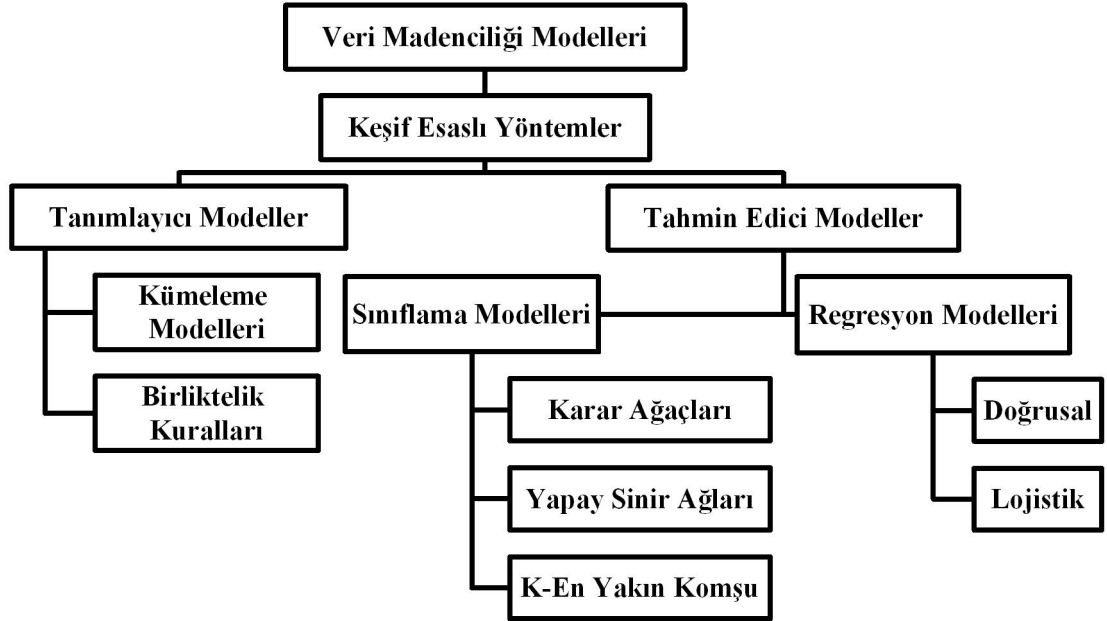
Değerlendirme: Bu aşamada önceki dört temel adım genel olarak değerlendirilir. Kurulan modellerin soruna çözüm sağlayıp sağlamayacağı, oluşturulan modelin doğru olup olmadığı tespit edilir. Modelin uygun olduğuna kanaat getirilirse uygulamada kullanılabilir. Aksi takdirde önceki aşamalar tekrar gözden geçirilmelidir.

Uygulama: Son bölüm olan uygulama aşamasında oluşturulan modelin kullanılabilirliğinin netleştirilmesi için model yeniden incelenir. Elde edilmek istenen çözüm doğrultusunda seçilen model uygulanır. Bu uygulama sonucunda elde edilen bilgi ilgili kurum veya kişilerin kullanabileceği şekilde düzenlenerek rapor edilmelidir.

4.4. VERİ MADENCİLİĞİ MODELLERİ

Veri madenciliği uygulamaları deney esaslı uygulamalar olması sebebiyle birden fazla algoritmanın ayrı ayrı denenmesinde fayda görülmektedir. Birbirinden farklı algoritmaların denenmesi sonucu en verimli sonuçları sağlayan algoritma seçilerek, bu algoritma yardımıyla uygulamada kullanılacak model belirlenebilir. Bununla birlikte, uygulamada kullanılan verilerin zaman içerisinde değişim geçirme olasılığı bulunduğundan, belirlenen modelin de zamanla güncelleştirilmesi gerekebilmektedir [49].

Şekil 4.2’de veri madenciliği modelleri gösterilmiştir.



Şekil 4.2. Veri madenciliği modelleri [50].

Veri madenciliği modelleri tahmin edici modeller ve tanımlayıcı modeller olmak üzere iki ana başlıkta incelenmektedir. Tahmin edici modeller kendi içerisinde sınıflama ve regresyon modelleri olmak üzere ayrılırken; tanımlayıcı modeller ise kümeleme ve birliktelik kuralları olarak iki ana kola ayrılmıştır.

4.4.1. Tahmin Edici Modeller

Tahmine dayalı madenciliğin amacı, tahminlerde bulunabilmek için elde bulunan veriler üzerinden çıkarım yapmaktır. Bu modelde sınıflama ve regresyon modelleri en çok kullanılan tekniklerdir. Sınıflama ve regresyon modellerinden faydalanılarak veri sınıfları oluşturulabilmekte ve verilerin gelecekteki eğilimleri tahmin edilerek çıkarımlarda bulunulabilmektedir. Kategorik değere sahip olan verilerin tahmininde sınıflandırma modeli kullanılırken, sürekli değere sahip olan verilerin tahmininde regresyon modelinden faydalanılmaktadır [51].

4.4.2. Tanımlayıcı Modeller

Tanımlayıcı modeller karar vermede yol gösterici olarak kullanılan, elde bulunan veriler arasındaki ilişkilerin tanımlanmasını sağlamaktadır. Bu modellerin amacı, veritabanında bulunan verilerin başlıca özelliklerini karakterize etmek ve veriler arasındaki ilişkiyi ortaya çıkarmaktır. Kümeleme ve birliktelik kuralları tanımlayıcı modellere birer örnektir.

4.5. VERİ MADENCİLİĞİ TEKNİKLERİ

Veri madenciliği tekniklerinin detaylı açıklaması aşağıda verilmiştir.

4.5.1. Sınıflayıcı Modeller

Veri madenciliği teknikleri arasında en çok kullanılan tekniklerden biri olan sınıflama modelleri aynı özellikleri taşıyan verileri tespit etmeyi amaçlamaktadır. Bu modelin oluşturulabilmesi için, önceden sonuçları bilinen durumları ve bu durumlardaki ilgili etkenlerin hangi değerlere sahip olduğunun bilinmesi gerekmektedir. Sınıflandırma, farklı kategorilere ait bazı özelliklerle tanımlanan bir nesnel kümesinin olduğunu varsaymaktadır [52].

Sınıflama modelinde başlıca karar ağaçları, yapay sinir ağları, genetik algoritmalar, K-en yakın komşu ve Naive-Bayes teknikleri kullanılmaktadır [35].

4.5.1.1. Karar Ağaçları

Karar ağaçları tekniği, hangi sınıfa ait olduğu bilinen bir veriden tümevarım uygulamasıyla öğrenilen ağaç modelinde bir karar yapısıdır [53]. Bu teknik, karmaşık ve büyük verilerin, küçük ve sade veri gruplarına bölünmesiyle uygulanan bir yöntemdir. Doğru olarak yapılan her bölme işlemiyle, sonuç gruplarına ait üyeler birbirine benzer hale gelmektedir. Karar ağacının kalitesi yapılan işlemlerin doğruluğuyla doğru orantılıdır [54]. Karar ağacı modeli özellikle büyük veri yığınlarının kullanıldığı sınıflamalarda ve hatalı bilgilerin bulunduğu problemlerde kullanılarak, çözüm sağlamaktadır [55].

İşletmeler veri madenciliği uygulamalarında maliyetinin düşük olması ve kolay entegrasyonu nedeniyle karar ağaçları modelini sıkça kullanmaktadırlar. En çok kullanılan karar ağacı algoritmalarından bazıları aşağıdaki gibidir.

IDE3 Algoritması (Iterative Dichotomiser 3): Bu algoritma 1986 yılında Ross Quinlan tarafından ortaya çıkarılmıştır [56], [57]. Diğer karar ağacı algoritmalarında olduğu gibi IDE3 algoritması da büyüme ve budama olarak iki aşamadan oluşur. Karar ağacı oluşturulurken tüm veriler en iyi bölünen tek özneliği seçmek için her düğümde sıralanır. Bu model karar ağacı oluştururken yalnızca kategorik sınıflandırmayı kabul eder. IDE3 algoritması, eğitim veri setinde çok fazla ayrıntı olduğunda doğru sonuç vermez, bu nedenle IDE3 algoritması ile bir karar ağacı modeli oluşturulmadan önce detaylı bir veri ön işleme işlemi gerçekleştirilmelidir.

C4.5 Algoritması: Bu algoritma Ross Quinlan tarafından IDE3 algoritmasının geliştirilmiş versiyonu olarak ortaya atılmıştır. IDE3 algoritmasının aksine daha görsel bir yapıya sahiptir. Yine IDE3 algoritması kategorik özellikleri dikkate alırken, C4.5 algoritması sayısal özelliklerin sınıflandırılmasını hedeflemektedir. C4.5 algoritması eğitim veri setinde bulunan fazla detaylar nedeniyle oluşan yanlış sınıflandırma hatalarını azaltmaya yönelik gelişmiş bir ağaç budama yöntemine sahiptir [58].


CART Algoritması (Classification and Regression Trees): 1984 yılında Breiman tarafından bulunmuştur. İkili karar ağacı oluşturan CART Algoritması, ID3 algoritmasından farklı olarak her sayıda düğüm oluşturmak yerine sadece iki tane dal meydana getirir [59]. CART algoritmasında optimum ayrılma için Entropi veya Gini yöntemleri kullanılmaktadır.

CHAID Algoritması (Chi-Squared Automatic Interaction Detector): 1980 senesinde Kaas tarafından bulunan bir tekniktir. CHAID algoritması veri ayırma sürecinde izlediği yol ile CART algoritmasına göre farklılık gösterir. CHAID algoritmasında optimum ayrılma için ki-kare testi kullanılmaktadır. Çoklu ağaç üreten CHAID, bu özelliği sayesinde ikili ağaç üreten ID3, CART ve C4.5 gibi algoritmalarından ayrılmaktadır [60].

4.5.1.2. Yapay Sinir Ağları

Yapay sinir ağları örüntü tanıma ve hatayı minimize etme amacıyla kullanılan bir tekniktir. Veriyi girdi olarak alıp kaydeden yapay sinir ağları tekniği, her işlemde yeni bir öğreti sağlayabilmekte ve girdiler arasındaki bağlantıyı inceleyip ortaya koyabilmektedir [61].

Yapay sinir ağlarının yapısı Şekil 4.3'te verilmiştir.



Şekil 4.3. Yapay sinir ağı yapısı [62].

Yapay sinir ağı yapılarının insan beyninden hareketle geliştirildiği bilinmektedir. Şekil 4.3.'te gösterildiği gibi, yapay sinir ağlarının yapısı girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmandan meydana gelmektedir.

Girdi katmanı, girdiler ve ağırlık öğelerinden meydana gelmektedir. Girdi değişkenleri ilgili ağırlıkla çarpıldıktan sonra gizli katmana aktarılır. Gizli katman dış ortamdan izole olan sinirlerden meydana gelmiş olup, içerisinde birden çok ara katman bulundurur. Bu katmanda aktarılan veriler işlenerek çıktı verisine dönüştürülür. Elde edilen çıktılar farklı bir ağ için girdi olarak kullanılır [63]. Bu model, geçmiş tecrübelerden öğrenme ve bilinmeyen ilişkilerin ortaya çıkarılması özellikleri nedeniyle sıkça kullanılmaktadır.

4.5.1.3. Bayes Sınıflandırma Algoritması

1812 yılında Thomas Bayes tarafından bulunan Bayes sınıflandırması, şartlı olasılıkları esas alarak, belirlenen sınıftaki bir değer meydana gelmesi olasılığını inceler ve bu değeri tahmin eder. Bu tahmin Bayes formülü ile yapılabilmektedir. Formül aşağıdaki gibidir.

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)} \quad (4.1)$$

- A, B : Olaylar
P(A|B) : B olayı meydana geldiğinde, A olayının meydana gelme ihtimali
P(B|A) : A olayı meydana geldiğinde, B olayının meydana gelme ihtimali
P(A), P(B) : A ve B olaylarının bağımsız olarak gerçekleşme ihtimali

Bayes sınıflandırması verilerin kolayca işlenmesi açısından avantajlı olsa da, uygulama sonucunda bir kural ortaya çıkarılması yerine olasılık tahmininde bulunulması dezavantaj sağlamaktadır.

4.5.1.4. Naive-Bayes Algoritması

Naive-Bayes algoritması Bayes teorisi temelinde geliştirilmiş olup, kategorik veriler üzerinde çalışmaktadır. Oluşturulan modelde öncelikle çıktıların öğrenme grubundaki öncelikli olasılık frekansı ve bağımsız değişkenler ile bağımlı değişkenlerin kombinasyonunun meydana gelme sıklığı hesaplanmaktadır. Elde edilen bu sıklıklar ve öncelikli olasılıklar sentezlenerek tahminde kullanılmaktadır [64].

Naive Bayes algoritması sayısal veriler üzerinde kullanıldığı gibi, metinsel veriler üzerinde de kullanılmaktadır. Günlük hayatta sıklıkla alınan e-posta ve mesajların içeriklerinin gerçekçi olup olmadığı, reklam ya da dolandırıcılık amacı taşıyıp taşımadığı bu algoritma sayesinde yüksek doğruluk oranı ile saptanabilmektedir [65].

4.5.1.5. K-En Yakın Komşu

K-En yakın komşu yöntemi 1950'li yıllarda ortaya çıkmış ancak, o günün koşullarındaki bilgi işlem imkânı artana kadar yaygın kullanıma başlanmamıştır. K-en yakın komşu algoritması uzayda birbirine yakın olan aynı tür veri gruplarının birbirinin komşusu olduğu varsayımından hareketle geliştirilmiştir. Bu modelin temel amacı kategorize edilmek istenen kümeye en yakın olan kümeyi tespit etmektir. Bu aşamada sınıflandırma işlemi en yakın komşu sayısının en çok sayıda olduğu sınıfa göre yapılmaktadır [66].

4.5.1.6. Genetik Algoritmalar

Genetik algoritmalar, yönlendirilmiş rastgele araştırma algoritmaların bir koludur. Doğal seçim ve canlılarda bulunan genetik değişimin benzerliğinden gerçekleştirilmektedir. Bu algoritma diğer algoritmalar gibi araştırma uzayında bulunan çıkarımların bir kısmının oluşturduğu bir başlangıç popülasyonunu kullanır. Başlangıç popülasyonu her nesilde doğal seçim ve yeniden üreme işlemleri aracılığı ile geliştirilir. En son neslin en kaliteli bireyi, problem için kullanılacak en iyi çözüm olmaktadır [67].

Genetik algoritma uygulamaları üç temel grupta incelenmektedir. İlk grup deneysel uygulamalardır. Bu uygulamada amaç genetik algoritmaların diğer optimizasyon algoritmalarına karşı üstünlüğünü ispatlamaktır. Bir sonraki grup olan pratik uygulamalar endüstri ve gerçek sorunların çözümlenmesi için kullanılmaktadır. Son grup üçüncü grup ise veri madenciliğinde bilgiye ulaşılması amacıyla kullanılır [67].

4.5.2. Regresyon Modelleri

Regresyon modelleri mevcut durumdaki verilerden yaptığı çıkarımlar doğrultusunda yeni değerler tespit etmeyi amaçlar. Bu modelde elde edilen sonuç bağımlı değişken, analizde kullanılan veriler ise bağımsız değişken olarak adlandırılmaktadır. Problemin karmaşıklığına göre verilerin sayısı değişkenlik göstermektedir. Problemin çözümü için analizde kullanılacak veriler, sonucu direkt olarak etkilemektedir. Bu nedenle sonuç üzerinde etkisi bulunmayan veriler model dışı bırakılabilmektedir [52].


Bağımlı değişkenin türüne göre regresyon analizleri; doğrusal, doğrusal olmayan, lojistik, cox regresyonu ve benzeri şekilde isimlendirilmektedir. Bunlar arasında en yaygın kullanıma sahip olan yöntem doğrusal regresyondur. Doğrusal regresyon bir değişkenin değerini diğer bir değişken yardımıyla tahmin etmeye çalışır [68].

4.5.3. Kümeleme

Kümeleme modelinde temel hedef, küme içerisindeki verilerin benzer özellikte olanlarının kümelere ayrılmasıdır. Veri tabanlarının boyutları arttıkça, verilerin analiz sonucunda problem görülmesi ihtimali yükselmektedir. Bu nedenle, büyük boyuttaki veriyi, daha küçük hale getirmek gerekecektir. Fakat, bu işlem yapılırken veriler düzenli bir durumda olmadığı için verileri bölmekte yeni problemlerle karşılaşılabilir. Bu problemlerin önüne geçmek için, kümeleme tekniği geliştirilmiştir [69].

Bu modelde Şekil 4.3' ten de anlaşılacağı üzere aynı kümenin elemanlarının birbirine benzemesi, farklı özellikteki kümelerin bulunması ve veri tabanındaki nesnelerin bu kümelere göre kategorize edilmesi amaçlanmıştır [70].

Koordinat düzleminde kümeleme örneğine ait görsel şekil 4.3'te verilmiştir.



Şekil 4.4. Koordinat düzleminde kümeleme örneği [70].

Kümeleme teknikleri kullanılarak, veri özellikleri arasındaki genel dağılım modelleri ve korelasyonlar incelenebilmektedir. Sınıflandırma tekniği ile de nesne gruplarını ayırt etmek mümkündür ancak bu teknik kümeleme tekniğine göre daha maliyetlidir. Bu nedenle, kümeleme tekniği alt küme oluşturulması ve sınıflandırılmasında ön işlem yaklaşımı olarak kullanılmaktadır. Örneğin, satın alma şekline göre bir müşteri grubu oluşturularak benzer satın alma şekline göre müşterileri kategorilere ayırmak için kümeleme yönteminden faydalanılabilir. Sınıflandırma tekniğinden farklı olarak, kümeleme tekniğinde elde edilen verilerin hangi kısıtlara göre gruplanacağı öngörülemez [71].

Kümeleme modelinin en sık kullanıldığı alan perakendecilik sektörüdür. Bu sektördeki yöneticiler, müşteri portföylerini kümeleme modeli ile kategorize ettikten sonra pazarlama stratejilerini kategori bazında oluşturularak işletme kârlılığını arttırabilmektedirler. En çok kullanılan kümeleme yöntemlerinden hiyerarşik kümeleme ve K-Means (K-ortalamlar) yöntemi aşağıda açıklanmıştır.

4.5.3.1. Hiyerarşik Kümeleme

Hiyerarşik kümeleme en çok bilinen ve kullanılan kümeleme tekniğidir. Bu teknik veri setindeki birimlerin birbirlerine olan uzaklık ya da benzerliklerini göz önünde bulundurularak birimleri birbirleriyle farklı aşamalarda bir araya getirerek ardışık

biçimde kümeler belirlemeye ve bu kümelere girecek elemanların hangi uzaklık veya benzerlik seviyesinde küme elemanlarının olduğunu belirlemeye yönelik yöntemlerdir [72].

4.5.3.2. K-Means (K-Ortalamlar) Tekniği

K-Means yöntemi, kümeleme problemini çözümlen en kolay öğrenme tekniklerinden biridir. Bu tekniğin temel mantığı n adet veri nesnesinden oluşan bir veri kümesini, giriş parametresi olarak verilen k adet kümeye bölümlenektir. Burada amaç, bölümlenme işlemi sonunda elde edilen kümelerin, küme içi benzerliklerinin maksimum ve kümeler arası benzerliklerinin minimum olmasını sağlamaktır. Tekniğin performansını k küme sayısı, başlangıç olarak seçilen küme merkezlerinin değerleri ve benzerlik ölçümü faktörleri etkilemektedir [64].

4.5.4. Birliktelik Kuralları

Birliktelik kuralları, bir veri tabanındaki verileri inceleyerek aralarında bir ilişki bulma üzerinde araştırmalar yapan bir çalışmadır. Bu teknik genellikle marketlerde kullanılmaktadır. Birliktelik kuralları yardımıyla market sahipleri müşterilerinin satın alma eğilimlerini gözlemleyebilir. Müşteri talebi doğrultusunda hareket edildiğinde ise karlılık oranı arttırılmış olacaktır. Bu teknik ile ilgili bilinen en yaygın örnek şu şekildedir: Amerika Birleşik Devletleri'nde oldukça tanınmış olan Walmart isimli süpermarketteki veriler incelendiğinde, cuma akşamları bebekleri için bez alan babaların genellikle bunun yanında bira da aldığı görülmüştür [73]. Bu analiz sonucunda Walmart bebek bezleri ve biraları yakın raflara koyarak satışlarını arttırmayı hedeflemiştir.

Başka bir örnek ise, günümüzde son derece yaygınlaşan internet aracılığıyla alışveriş yapan müşteriler sepetlerine bir ürün eklediklerinde, web sitesi o ürün ile ilişkili başka ürünleri de önermektedir.

Birliktelik kurallarında en sık kullanılan algoritmalar AIS, SETM, Apriori, Apriori-TID ve GRI algoritmalarıdır. Bu algoritmaların açıklamaları ile birliktelik kuralları bir sonraki bölümde detaylı olarak ele alınmıştır.

BÖLÜM 5

BİRLİKTELİK KURALLARI

Agrawal, Imielinski ve Swami 1993'te birliktelik kuralından bahsetmiştir [74]. Birliktelik kuralları analizi esasında geçmişte elde edilen verilerin birliktelik hareketlerinin takip edilmesi ile bize geleceğe dair potansiyel müşteri davranışlarının yapılanmasını gösteren yaklaşımlardır.

Bir alışveriş esnasında müşterilerin hangi ürün veya hizmeti satın aldığı belirlenmesi ve müşteriye o ürün veya hizmet ile alakalı daha fazla satış yapılmasını sağlayan yöntemlerden biridir. Market sepet analizi birliktelik kuralına en güzel örnektir. Bu analiz ile müşterilerin satın aldıkları ürün veya hizmet arasındaki ilişkiyi bularak, bu veriler sayesinde müşterilerin satın alma eğilimini tespit edilebilir. Bu birliktelik bağlantıları ile bankacılık, market ve diğer sektörler müşterilerin alışveriş alışkanlıklarını kullanarak daha etkin satış ve pazarlama yöntemleri geliştirmektedirler. Örneğin bir kitapçıda eğer genç kitapları, kaynak kitaplar ve coğrafya kitabı alınıyorsa %90 oranında çocuk kitapları da alınma olasılığı vardır. Kitapçılar birliktelik kuralları analizini kullanarak müşterilerinin satın alma eğilimlerinin neler olduğunu belirleyebilirler. Birliktelik kuralları muhasebe, market, satış ve pazarlama gibi sektörlerde daha yaygın olarak kullanılmaktadır [75].

Perakende sektöründe faaliyet gösteren bir market dinamik bir veri tabanına sahip olacağı için, bu veri tabanını ele alacak olursak;

“X → Y” bir ilişki kuralı, “X” bir neden (Antecedent) ve “Y” ise sonuç (Consequent) olarak nitelendirilir. Birliktelik kurallarında önemli verileri önemsiz verilerden ayırmak son derece önemlidir. Bu sebeple, destek (Support) ve güven (Confidence) ölçüt değerleri kullanılmaktadır.

$$\text{Destek } (x \Rightarrow y) = P(X \cup Y) \quad (5.1)$$

$$\text{Destek } (X \Rightarrow Y) = \frac{\text{X ve Y ürünlerini satın alan müşteri sayısı}}{\text{Toplam müşteri sayısı}} \quad (5.2)$$

$$\text{Güven } (X \Rightarrow Y) = \frac{\text{Destek } (X \Rightarrow Y)}{\text{Destek } (X)} \quad (5.3)$$

$$\text{Güven } (X \Rightarrow Y) = \frac{\text{X ve Y ürünlerini satın alan müşteri sayısı}}{\text{X ürünlerini satın alan müşteri sayısı}} \quad (5.4)$$

X ve Y ürünlerini satın alan müşteri sayısının, toplam müşteri sayısına bölünmesiyle destek formülü elde edilir.

Güven formülüne göre ise, X ve Y ürünlerini birlikte satın alan müşteri sayısının, X ürünlerini satın alan müşteri sayılarına bölünmesiyle güven elde edilir. Güven değerinin 0 çıkması, X ürününün bulunduğu işlemlerin hiçbirinde Y ürününün bulunmadığı anlamına gelmektedir [76].

5.1. BİRLİKTELİK KURALLARINDA SIK KULLANILAN ALGORİTMALAR

5.1.1. AIS Algoritması

1993 senesinde Agrawal, Imielinski ve Swami tarafından geliştirilip yayınlanan AIS algoritmasının amacı nitelikli veri setleri elde etmektir. Bu algoritma iki temel adımdan meydana gelmektedir. İlk adım, sürekli kullanılan veri setlerinin meydana getirilmesidir. İkinci adımda ise, sürekli kullanılan ürün topluluklarındaki ürünlerin birbirleri ile ilişkisi ortaya çıkarılır. AIS algoritmasının dezavantajı, veri tabanı üzerinde çoklu aşamalar oluşturmaktır.

Veriler birçok defa taranır ve buradan ortaya çıkan atıl, niteliksiz veriler zaman kaybı ve gereksiz alan işgal etme gibi sorunlara yol açabilmektedir [77].

5.1.2. SETM Algoritması

AIS algoritmasında olduğu gibi, SETM algoritması da veri tabanlarında taramalar gerçekleştirir. Taramanın ilk aşamasında her bir veri için destek sayısını saymasının yanı sıra, en yaygın olanı saptar. Bir sonraki aşamada ise, tarama sürecinde belirlenen ürün grupları yardımıyla aday kümeleri saptar. SETM algoritması aday kümeleri oluşturma işlemi için SQL birleştirme işlemi uygulayarak sayım ile aday oluşturmayı ayırır. Oluşturulan işlemin TID'si ile birlikte aday öge setinin bir kopyasını sıralı bir yapıda sisteme kaydeder. Bu özelliği ile SETM, diğer algoritmalarından ayrılmaktadır. Son aşamada, aday ürün grupları ürün adına göre sıraya diziler ve küçük ürün grupları ayıklanır. Algoritmanın sonlandırılması için yeni bir yaygın ürün grubu oluşmamış olması gerekmektedir [78].

5.1.3. Apriori Algoritması

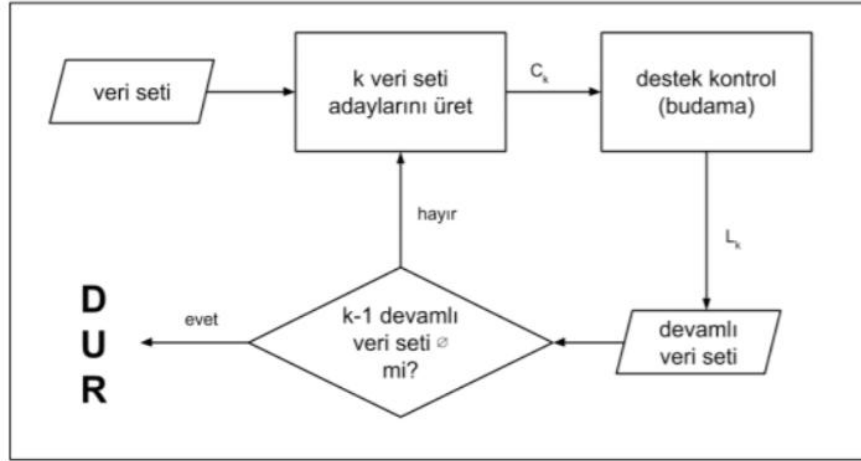
1994 senesinde Agrawal ve Srikant tarafından geliştirilen Apriori algoritması, birliktelik kuralları algoritmaları arasında oldukça yaygın bir kullanıma sahiptir [79].

Apriori, tekrarlı bir yaklaşım kullanır. Bu yönteme göre k-nesne kümeler, (k+1) nesne kümelerin incelenmesi için kullanılır. İlk adımda, en çok kullanılan 1 nesnekümesi, minimum desteğe sahip olan verilerin toplanmasıyla elde edilir. Elde edilen bu küme L_1 olarak isimlendirilir. L_1 kümesi L_2 'yi (sık geçen 2-nesneküme kümesi) elde etmek için kullanılır. L_2 ise L_3 'ün elde edilmesinde kullanılır. Bu işlem daha sık geçen k-nesne kümeler elde edilmeyene kadar tekrarlı olarak sürdürülür. Her bir L_k değerinin elde edilebilmesi için her defasında veri tabanının tümünün taranmasını gerektirir [80].

Apriori algoritmasının iki farklı dezavantajı bulunmaktadır. Bunlardan ilki, aday oluşturma süreci son derece karmaşıktır.

Bu durum zaman ve bellek israfına da yol açabilmektedir. İkincisi ise, veri tabanının birden çok kez taranmasını gerektirmesidir [81].

Apriori akış diyagramı şekil 5.1’de verilmiştir.



Şekil 5.1. Apriori akış diyagramı [82].

5.1.4. Apriori-TID Algoritması

Apriori algoritmasında destek değerleri saptanırken her defasında tüm veri tabanının taranması gerekmektedir. Bu durum gereksiz zaman kaybı ve iş gücü kaybına yol açmaktadır. Agrawal ve Srikant bu problemi ortadan kaldırmak için Apriori-TID algoritmasını geliştirmiştir. Bu algoritma Apriori’nin aksine, ilk geçişten sonra destek değerinin belirlenmesi için veri tabanını tekrar taramaz [83].

Birliktelik kural algoritmalarının karşılaştırması Çizelge 5.1’de verilmiştir.

Çizelge 5.1. Birliktelik kural algoritmalarının karşılaştırması [78].

Özellikler	AIS	SETM	Apriori	Apriori-TID
Veri Desteği	Az	Az	Sınırlı	Genellikle Geniş
İlk Aşamadaki Hız	Yavaş	Yavaş	Yüksek	Yavaş
Son Aşamadaki Hız	Yavaş	Yavaş	Yavaş	Yüksek
Doğruluk	Çok az	Az	Az	Apriori’den daha yüksek

AIS, SETM, Apriori ve Apriori-TID birliktelik kural algoritmaları karşılaştırıldığında, her algoritmanın kendi içerisinde hem avantajlı hem de dezavantajlı olduğu özellikler görülmektedir. Bu algoritmalar arasında Apriori-TID algoritmasının diğer algoritmalara göre daha avantajlı ve kullanışlı olduğu söylenebilir.

5.1.5. GRI Algoritması

Kuralların farklılığını hesaplamak için GRI algoritması bir nicel ölçek ve böyle bir önlemlerle olası değerleri sınırlar [84]. GRI, bilgiye ulaşmak ve içindeki farklılığı ölçmek için nicel yaklaşım (J) aday birliktelik kurallarını kullanır. Bu algoritma nicel yaklaşım ölçeğini (J) mümkün olduğunca sınırdan farklı ölçerek hesaplar. Böylelikle anlamlı kurallar arama alanını daraltmaktadır.

En önemli verilerden oluşturulan kuralları bulmak için (J) indeksini oluşturur. Aday birliktelik kurallarını şöyle özetler: oluşturulan indeks dizinin terimi ve kuralları dikkate alınarak listeler hazırlanıp destek ve güven değerlerinin hesapları yapılır. Sonuç olarak daha az numaralı ve daha mantıklı kuralların kullanıldığı bir alan oluşturulmuştur. GRI algoritmasının avantajlarından biri de anlamlı olan verilerin içindeki önemsiz olanları kaldırmaktır.

GRI algoritmasının formülü aşağıdaki gibidir.

$$J(X;Y =y) = P(x/y) * \log \left(\frac{P(x/y)}{P(x)} \right) + (1-P(x/y)) * \left(\log \left(\frac{1-p(x/y)}{1-p(x)} \right) \right) \quad (5.5)$$

P(x): Kuralın sol (öncül) tarafının oluşma olasılığı

P(y): Kuralın sağ (sonuç) tarafının oluşma olasılığı

BÖLÜM 6

LİTERATÜR

Literatürde market sepet analizi ile ilgili birçok çalışma yer almaktadır. Bunlardan bazıları aşağıdaki gibidir.

Döşlü (2008) çalışmasında; Migros Kadir Has mağazasının 2007 yılı Mayıs ayına ait bir aylık veri setini kullanarak Apriori algoritmasını uygulamıştır. Çalışmada birliktelik kurallarının elde edilmesi amaçlanmıştır. Çalışma sonucunda, algoritmalar karşılaştırılmış olup, FP-Growth algoritmasının Apriori algoritmasından daha yüksek performans gösterdiği saptanmıştır [31].

Gündüz (2017) çalışmasında, bir alışveriş merkezinin 2017 yılına ait ürün adı, alışveriş tarihi, ürün kategorisi gibi verilerini kullanarak Apriori algoritmasını kullanmış, IBM SPSS Clementine paket programıyla çözümlene yapmıştır. Elde edilen sonuca istinaden raf düzenlemeleri ve market içi yerleşim konularında geliştirme yapılmıştır. Yapılan analiz sonucunda, en fazla güven değeri sağlayan ev ve mutfak eşyaları ile temizlik bölümlerinin birlikte görülme olasılıklarının en yüksek olduğu tespit edilmiştir [83].

Tokyürek (2019) çalışmasında, bir mağaza deposuna ait 4625 adet işlem ve 106 adet üründen meydana gelen bir veri setini baz alarak birliktelik kural çıkarım algoritmaları kullanılarak depodan birlikte çıkma eğilimi olan ürünler belirlenmiştir. Deponun giriş-çıkış için optimal hale getirilmesi amaçlanarak FP-Growth ve Apriori algoritmalarından faydalanılmıştır. Uygulama sonucunda her iki algoritmanın da birbirine yakın sonuçlar verdiği ancak kural sayıları ve kural meydana getirme sürelerinin farklı olduğu görülmüştür [85].

Soylu (2019) çalışmasında, Migros Ticaret A.Ş.'nin 2015 senesi Ocak ve Aralık ayları arasındaki bir yıllık müşteri alışveriş kayıtlarını ele almıştır. Veri seti toplam 118.479 alışveriş kaydından oluşmaktadır. Bu veriler, birliktelik kuralları ile analiz edilerek müşterilerin satın alma eğilimleri ortaya çıkarılmıştır. Müşterilerin ortak satın alma eğilimleri ise apriori algoritmasından faydalanılarak tespit edilmiştir. Apriori algoritması uygulaması sonucu kâğıt ve bebek ürünleri alanların yüzde 90,222 güven aralığıyla ekonomik ürünlerle birlikte görülmüştür [86].

Deveci ve Baysal (2019) çalışmasında, Ege bölgesindeki bir perakende zincirinin tüm mağazalarındaki altı aylık alışveriş verilerini incelemiştir. Bu analizde 60.284 müşterinin verisi ve 6.406.485 satırlık alışveriş fişi kullanılmıştır. Bu veriler sepet verisi yaygın nesne kümesi madenciliği ve yüksek faydalı nesne kümesi madenciliği algoritmaları kullanılarak incelenmiştir. Bu çalışmada yaygın nesne kümesi madenciliği algoritmaları içinden FP-Growth, Apriori ve Eclat algoritmaları kullanılmıştır. Perakende zincirinin kendi markası olan üçlü kâğıt havlu, ıslak havlu, pudra kokulu tuvalet kâğıdı ve kağıt peçetenin en çok satılan ürünler olduğu sonucuna ulaşılmıştır [87].

Gurudath (2020) çalışmasında, Instacart adlı uygulamanın açık kaynaklarını kullanmıştır. Bu veriler dahilinde 200.000 müşterinin üç milyon tane siparişi ele alınmıştır. Bu çalışmada siparişler ile siparişlerin verildiği tarihlere özellikle dikkat edilmiştir. Araştırmanın amacı, Apriori ve FPGrowth algoritmalarını kullanarak müşterilerin hangi ürünleri hangi zaman aralıklarında aldığını bulmaktır. Yapılan uygulama sonucunda Instacart'ta en çok muz satıldığı ve muzun yanında çilek, elma, salatalık, elma, avokado ve limon gibi ürünlerin birlikte görüldüğü sonucuna varılmıştır. Eğer bir tüketici muz alıyorsa yukarıdaki 6 meyveden biri ile birlikte görülme olasılığı yüksektir [88].

Kamakura (2012); her alışverişte beş ve daha fazla ürün alan tüketicileri bir alışveriş turu olarak tanımlamıştır. Bu veriler sadece bir tane marketten elde edilen verilerdir.

Toplamda 2.290 alışveriş turu atılmış olup 15.206 kere alım yapılmış olup 56.508 ürün satılmıştır. Gerçek alımlar yalnızca kasaya gidilip ödeme yapıldığında sayılmıştır. Satın alma sırasında geçirilen zaman ve yol alışveriş turuna dahil edilmemiştir. Sonuçlara göre, üzüm alan tüketicilerin, bunun yanında yüzde 73 güvenle elma da aldığı ortaya çıkmıştır [89].

Annie ve Kumar (2012); Anantha mağazalarında her işlemde satılan ürünleri keşfederek işe koyulmuşlar. Anantha mağazaları sekiz bölümden oluşmaktadır. Bunlar ev eşyaları, meyve ve sebzeler, fırın mamulleri, mutfak araç gereçleri, oyuncaklar, hediyelik eşyalar, tekstil ve eczaneden oluşmaktadır. Apriori ve K-Apriori algoritmaları kullanılarak sonuçlar elde edilmiştir. K-Apriori algoritması ilişkilendirme ve bilgilendirici öge setlerini daha etkin kullanarak Anantha mağazalarının mallarının nereye daha etkili bir şekilde yerleştirilmesinde öncü rol oynamıştır. Sonuç olarak K-Apriori algoritması ile yapılan market sepet analizine göre Anantha mağazaları yıllık gelirlerini bir hayli artırmaktadır [90].

Hilage ve Kulkarni (2011); alışveriş merkezlerinde Apriori algoritmasını uygulayarak ayçiçek yağı, şeker ve rava'nın birbirleriyle ilişkili olduğunu gözlemlemiştir [91].

Attal vd. (2018); projelerinde perakende sektöründeki ürünler arasındaki ilişkileri bulmak için Market sepet analizi tekniğini uygulamışlardır. Bu ilişkiler üç ölçüde ele alınır; destek, güven ve kaldırma. Yaptıkları çalışmada çeşitli yaklaşımlar geliştirmişlerdir. Bu yaklaşımlar; satış noktası verileri elde etmek, gereksiz verileri temizlemek, bu verileri kategorilere ayırmak, farklı algoritmalar uygulamak, bunlardan yararlı olanları ayıklamak ve son olarak da markette yeni bir yerleşim planı oluşturmaktır. Yaptıkları çalışma sonucunda en çok meyve ve sebzenin satıldığını bulmuşlardır. Cips alan birinin yanında çikolata alma olasılığının yüzde 72 oranında, çikolata alan birinin yanında meyve ve sebze alma oranının yüzde 66 olduğunu elde etmişlerdir [92].

Nandy (2018) çalışmasında, Malezya'daki perakende sektöründeki mağazaları incelemiş ve Apriori, Eclat and FP Growth algoritmalarına bu mağazalarda yer

vermiştir. Eclat algoritmasını uyguladıktan sonra 304 numaralı departmanda satılan deodorantlar, duş jeli ve sabunların; 302 numaralı departmandaki traş losyonları, vücut bakım malzemeleri ve temizlik ürünlerinin beraber alındığı sonucuna ulaşmıştır. Eğer 302 numaralı departmanda bir indirim yapılırsa yapılan indirimin 302 ve 304 numaralı departmanlarda satışı arttırdığı görülmüştür [93].

Prasad (2011) çalışmasında, perakende satış mağazasının neleri satışa sunacağı, verilecek kuponların nasıl ve ne zaman tasarlanacağı ve kârı zirveye taşımak için raflara ürünlerin nasıl yerleştirilmesi gerektiğini açıklamıştır. Bunun içinde Apriori algoritmasını kullanmıştır. Sonuç olarak, ilişki kuralı madenciliği uygulamasının kullanılmasının perakendecilere müşteri davranışlarına ve ürünlerin satış eğilimlerine dair yeterli bilgiler verdiği görülmüştür [94].

Gülce (2010), bir yüksek lisans çalışmasında perakende satış yapan bir firmanın ürünleri için birliktelik kuralını uygulamıştır. Bu çalışmada futbol taraftar gruplarına anketler verilmiş ve taraftarlardan gerekli veriler toplanmıştır. Bu çalışmada elde edilen sonuca göre, cinsiyeti erkek olan birinin taraftar ürünü alması olasılığı %87 civarındadır. Tam zamanlı çalışan bir kişinin taraftar ürünü alma olasılığı %88 civarında olduğu görülmüştür [95].

Gülen ve Özdemir (2013), üstün yetenekli öğrencilerin hangi alanlara ilgili olduğunu anlamak için sınıflandırma algoritması kullanılmıştır ve sonuçlar değerlendirilerek en uygun olanı seçilmiştir. Apriori algoritması kullanılarak üstün yetenekli öğrencilerin ilgi duydukları alanlar belirlenmiştir. Bu çalışmadan elde edilen birliktelik analizi sonuçlarına göre ders programlarının düzenlenmesi planlanmıştır. Çalışma sonucunda öğrencilerin ilgi duydukları bölümlere ait derslerin farklı saatlerde gerçekleşmesi halinde, öğrencilerin hem birinci hem de ikinci olarak ilgi duyduğu alanlarla ilgili derse katılabileceği konusunda öneri de bulunulmuştur [96].

Gedleç (2019), market sepet analizi, Türkiye’de perakende sektöründe yer alan bir işletmenin belirli dönemlere ait fiş kayıtları üzerinde yapılmıştır ve çalışmada apriori algoritması kullanılmıştır. Sonuçlara göre en çok birlikte görülen 7 ürün, salatalık, domates, ekmek, süt, yumurta, sigara ve dana etidir [97].

Sağın (2018) çalışmasında, büyük bir hırdavat şirketinin şubesinden alınan satış verilerini kullanmıştır. Birliktelik analizi kurallarından olan Apriori ve FP-Growth algoritmalarını kullanarak, veri seti içerisindeki birliktelik kurallarını ortaya çıkarmıştır. Analiz sonuçlarına göre en güçlü birlikteliklerin; murç ve keskiler, bits uçlar, matkap uçları, panç grubu, metreler, somun adaptörleri ve eğeler arasında olduğu görülmüştür [98].

Poel vd. (2004), perakende sektöründe hizmet veren bir firmadan alınan yıllık veriler üzerinden market sepeti analizi ile ürün çiftlerini belirlemişlerdir. Bu çalışmada, uygulanan promosyonlarla ürün çiftlerinin satın alınmasında bir değişiklik olup olmadığı kontrol edilmiştir [99].

Güllüoğlu (2015) çalışmasında; birliktelik kurallarından Apriori uygulamasını kullanarak en çok tercih edilen ürün gruplarını yaş ve cinsiyete göre belirlemiştir. Bu çalışmada İstanbul'da bulunan bir süpermarketin 300 adet müşterisine ait olan satış verileri kullanılmıştır [100].

Tekin vd. (2015) çalışmasında; Konya'da bulunan bir süpermarketten elde ettiği 962 bin fişten oluşan veri setini kullanmışlardır. Bu çalışmada Apriori uygulaması kullanılarak müşterilerin satın alma davranışları incelenmiştir. Taze sebze ve meyveler, et ürünleri ile ilişkilendirilirken, hazır giyim grubunun bisküvi ile ilişkisi olduğu görülmüştür [101].

Ertuğrul vd. (2016), Apriori algoritmasını raf dizaynı için kullanmıştır. 16 çeşit bisküvinin 750 müşteri tarafından satın alındığı ve bu verilere göre de bisküviler için özel raf dizaynı düzenlendiği görülmüştür [102].

Bu tez çalışmasının amacı, veri madenciliğinin temel kavramları olan market sepet analizi ve birliktelik kuralları yardımıyla perakende sektöründe hizmet gösteren bir markete ait veriler üzerinde yapılan uygulama sonucu müşteri alışveriş eğilimini belirlemektir. Ayrıca, Covid-19 salgını öncesi ve sonrası dönemde tüketici alışveriş eğilimlerinin incelenmesidir.

Bu alıřmada, perakende sektöründe faaliyet gösteren bir markete ait veri seti baz alınarak, en ok bilinen birliktelik kuralı algoritmaları olan Apriori ve GRI algoritmaları kullanılmıř ve IBM SPSS Modeler veri madencilięi yazılımı ile analiz edilmiřtir. Yapılan analiz sonucunda birliktelik kuralları yorumlanmıř olup Covid-19 pandemisi öncesi ve sonrası tüketici satın alma eęilimleri incelenmiřtir.

BÖLÜM 7

YÖNTEM VE UYGULAMA

7.1. PROBLEMİN TESPİTİ

Bu tez çalışmasında, perakendecilik sektöründe faaliyet gösteren bir marketin verileri üzerinde yapılan analizlerle, birlikte satın alınan ürünlerin tespit edilmesi, bu ürünler arasındaki ilişkinin ortaya çıkarılması ve Covid-19 pandemi dönemi öncesi ve sonrası tüketici alışveriş eğilimindeki değişimin incelenmesi amaçlanmıştır. Mevcut durumda bazı ürünlerin satışlarının çok düşük oranda olması ve bu ürünlerden elde stok bulunması problemi, raf dizilimlerinin yeniden gözden geçirilmesi ihtiyacını doğurmuştur. Satış oranı düşük olan ve elde bol miktarda bulunan bu ürünler arasında son tüketim tarihleri yaklaşan ürünler de bulunmaktadır. Bu çalışmada Apriori algoritması kullanılmıştır. Çalışma sonucunda marketin karlılığını artırmak ve müşteri memnuniyetsizliklerinin önüne geçmek amaçlanmaktadır.

Örneklem olarak Amerika Birleşik Devletleri'nin Massachusetts eyaletinde perakendecilik sektöründe hizmet veren bir işletmenin ERP programı yardımıyla 20.10.2019 - 19.08.2020 tarihleri arasındaki on aylık sürede alışveriş yapan toplam 213.455 adet satış kaydı kullanılmıştır. Ham veri setinden bir bölümün ekran görüntüsü Çizelge 7.1'de gösterilmektedir.

Çizelge 7.1. Ham veri setinden bir bölümün ekran görüntüsü.

POS_Station	Order_Number	Order_Type	Order_Date	Payment_Amount	Product_Name	Barcode	Sku	Product_Price	Category	Sub_category	Class	Gross_Item_Price	Total_Sales_Price	Product_Quantity
POSS	83734	To Go	20.10.2019 08:27	18,01	C2O Coconut Water 17.5	853883003008	100000066584	2,49	Beverage & Juices	Juice	Beverage & Juices (C	2,49	2,49	1
POSS	83748	To Go	20.10.2019 08:52	6,48	Avocados-N (ea)	4225	sku13	1,99	Fruits	Stone Fruit	Produce & Floral (Cl	1,99	1,99	1
POSS	83748	To Go	20.10.2019 08:52	6,48	NestFresh Large Pasture	736921000392	100000066133	4,49	Eggs	Eggs	Dairy & Eggs (Class)	4,49	4,49	1
POS4	83754	Eat In	20.10.2019 09:26	6,79	Balparmak Pine Honey S	192642000132	100000012796	6,79	Honey, Sweeteners & Syrups	Honey	Honey & Spreads (Cl	6,79	6,79	1
POSS	83760	To Go	20.10.2019 09:35	7,27	Garuka Bars	860496000607	100000057926	2,99	Nutrition & Granola Bars	Granola Bars	Snacks (Class)	2,99	2,99	1
POS1	83761	Eat In	20.10.2019 09:36	15,26	Sea Point Farms Organic	711575004965	100000051771	4,29	Frozen Foods	Frozen Fruit & Vegetal	Frozen Foods (Class)	4,29	4,29	1
POS1	83761	Eat In	20.10.2019 09:36	15,26	NestFresh Pasture Raise	736921100108	100000068274	4,99	Eggs	Eggs	Dairy & Eggs (Class)	4,99	4,99	1
POS1	83761	Eat In	20.10.2019 09:36	15,26	Lettuce, Romaine Hearts	651003214	sku24	3,99	Vegetables	Lettuce	Produce & Floral (Cl	3,99	3,99	1
POS1	83761	Eat In	20.10.2019 09:36	15,26	Avocados-N (ea)	4225	sku13	1,99	Fruits	Stone Fruit	Produce & Floral (Cl	1,99	1,99	1
POSS	83767	To Go	20.10.2019 09:47	192	Coffee Box 96 oz (serves	100000025598	100000057896	24	Catering	Catering	Catering (Class)	24	192	8
POS1	83769	Eat In	20.10.2019 09:54	15,35	Imported Swiss Cheese	60046	100000065525	3,08	Cheese	Swiss	Cheese & Charcuteri	3,08	3,08	1
POS1	83769	Eat In	20.10.2019 09:54	15,35	Stone and Skillet Origina	862069000106	100000069714	4,79	Breads	English Muffins/Bagels	Bakery (Class)	4,79	4,79	1

Düzenlenen veri seti, 20.10.2019-10.03.2020 tarihleri arasındaki alışveriş kayıtları Covid-19 pandemi öncesi satılan ürün gruplarını, 11.03.2020-19.08.2020 tarihleri arasındaki alışveriş kayıtları ise Covid-19 pandemi sonrası satılan ürün gruplarını temsil etmek üzere iki farklı veri seti olarak ayrılmıştır.

Çizelge 7.2’de Covid-19 pandemi öncesi satılan ürün gruplarının veri seti verilmiştir.

Çizelge 7.2. Pandemi öncesi satılan ürünler.

Müşteri Numarası	Alışveriş Tarihi	İçecekler	Meyveler	Yumurtalar	Bal ve Tatlandırıcılar	Protein Barları	Dondurulmuş Yiyecek	Sebzeler	Peynirler	Ekmekler	Kurabiye ve Kekler	Unlu Mamul	Süt Ürünleri	Atıştırmalıklar	Cips Sosları	Poşet	Yemek Malzemeleri	Şarküteri	Züccaciye	Çay	Et İçerikli Atıştırmalıklar	Soslar	Mısır Gevrekleri	Reçeller	Tozlu İçecekler	Kuruyemiş	Şekerleme ve Çikolatalar	Zeytinler	Kişisel Bakım	Baharatlar ve Çeşniler	Vitaminler	Et	Yağlar	Sirkeler	Temizlik Ürünleri	Tavuk Ürünleri	Deniz Ürünleri	Kahve	Bebek Ürünleri	Kağıt Havlu Ürünleri	Turşular	Tatlılar	Etnik			
83734	10/20/2019 08:27:55	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
83748	10/20/2019 08:52:16	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
83754	10/20/2019 09:26:00	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
83760	10/20/2019 09:35:43	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
83761	10/20/2019 09:36:58	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
83769	10/20/2019 09:54:48	0	1	1	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
83772	10/20/2019 10:02:34	0	0	1	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
83774	10/20/2019 10:03:33	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
83780	10/20/2019 10:05:47	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
83784	10/20/2019 10:16:38	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Pandemi öncesi veri seti, birliktelik analizi için 0,1 matris formatına uygun olarak düzenlenmiştir. Pandemi öncesi, yani 20.10.2019-10.03.2020 tarihleri arasında toplam 13.983 adet müşteri mağazadan alışveriş yapmıştır.

Covid-19 pandemi sonrası satılan ürün gruplarının veri seti çizelge 7.3'te verilmiştir.

7.2. TANIMLAYICI İSTATİSTİKLER

Eldeki verilerde 213.455 adet ürün satışının içerisinde ürünler, veri madenciliği aşamalarından olan temizleme ve filtreleme işlemlerinin ardından 42 farklı ana gruba indirgenmiştir. Bu işlemin yapılma sebebi anlamlı olmayan verilerin uygulama dışı bırakılmasıdır. Son durumda, oluşan ana ürün grupları Çizelge 7.4’te verilmiştir.

Çizelge 7.4. Ana ürün grupları.

Ürün Grupları			
1	İçecekler	22	Mısır Gevrekleri
2	Meyveler	23	Reçeller
3	Yumurtalar	24	Tozlu İçecekler
4	Bal ve Tatlandırıcılar	25	Kuruyemiş
5	Protein Barları	26	Şekerleme ve Çikolatalar
6	Dondurulmuş Yiyecek	27	Zeytinler
7	Sebzeler	28	Kişisel Bakım
8	Peynirler	29	Baharatlar ve Çeşniler
9	Ekmekler	30	Vitaminler
10	Kurabiye ve Kekler	31	Et
11	Unlu Mamul	32	Yağlar
12	Süt Ürünleri	33	Sirkeler
13	Atıştırmalıklar	34	Temizlik Ürünleri
14	Cips Sosları	35	Tavuk Ürünleri
15	Poşet	36	Deniz Ürünleri
16	Yemek Malzemeleri	37	Kahve
17	Şarküteri	38	Bebek Ürünleri
18	Züccaciye	39	Kâğıt Havlu Ürünleri
19	Çay	40	Turşular
20	Et İçerikli Atıştırmalıklar	41	Tatlılar
21	Soslar	42	Etnik

Pandemi öncesi ve sonrası satış değerleri ile yüzde değerleri Çizelge 7.5’te verilmiştir.

Çizelge 7.5. Pandemi öncesi ve sonrası sepet alışveriş istatistikleri.

	Ürün	Pandemi Öncesi Satış Adedi	P.Ö. Satışların P.Ö. Toplam Satışa Oranı	Pandemi Sonrası Satış Adedi	P.S. Satışların P.S. Toplam Satışa Oranı
1	İçecekler	4034	0,14	6196	0,06
2	Meyveler	2442	0,09	8926	0,09
3	Yumurtalar	825	0,03	3046	0,03
4	Bal ve Tatlandırıcılar	168	0,01	701	0,01
5	Protein Barları	317	0,01	309	0,01
6	Dondurulmuş Yiyecek	1699	0,06	7696	0,07
7	Sebzeler	2166	0,08	8724	0,08
8	Peynirler	740	0,03	3892	0,03
9	Ekmekler	1096	0,04	3952	0,04
10	Kurabiye ve Kekler	1058	0,04	3252	0,03
11	Unlu Mamul	252	0,01	2613	0,02
12	Süt Ürünleri	2508	0,09	7047	0,07
13	Atıştırmalıklar	2493	0,09	4656	0,04
14	Cips Sosları	523	0,02	2096	0,02
15	Poşet	12	0	29	0
16	Yemek Malzemeleri	1536	0,05	5680	0,05
17	Şarküteri	285	0,01	1103	0,01
18	Züccaciye	320	0,01	155	0,01
19	Çay	178	0,01	870	0,01
20	Et İçerikli Atıştırmalıklar	296	0,01	330	0,01
21	Soslar	383	0,01	1545	0,01
22	Mısır Gevrekleri	209	0,01	834	0,01
23	Reçeller	301	0,01	1556	0,01
24	Tozlu İçecekler	49	0	64	0
25	Kuruyemiş	718	0,03	2780	0,03
26	Şekerleme ve Çikolatalar	1188	0,04	2931	0,03
27	Zeytinler	422	0,02	956	0,01
28	Kişisel Bakım	338	0,01	2550	0,03
29	Baharatlar ve Çeşniler	196	0,01	1227	0,01
30	Vitaminler	124	0	254	0,01
31	Et	207	0,01	1664	0,01
32	Yağlar	457	0,02	1086	0,01
33	Sirkeler	64	0	416	0,01
34	Temizlik Ürünleri	154	0,01	1841	0,02
35	Tavuk Ürünleri	245	0,01	1882	0,02
36	Deniz Ürünleri	148	0,01	836	0,01
37	Kahve	158	0,01	884	0,01
38	Bebek Ürünleri	65	0	107	0

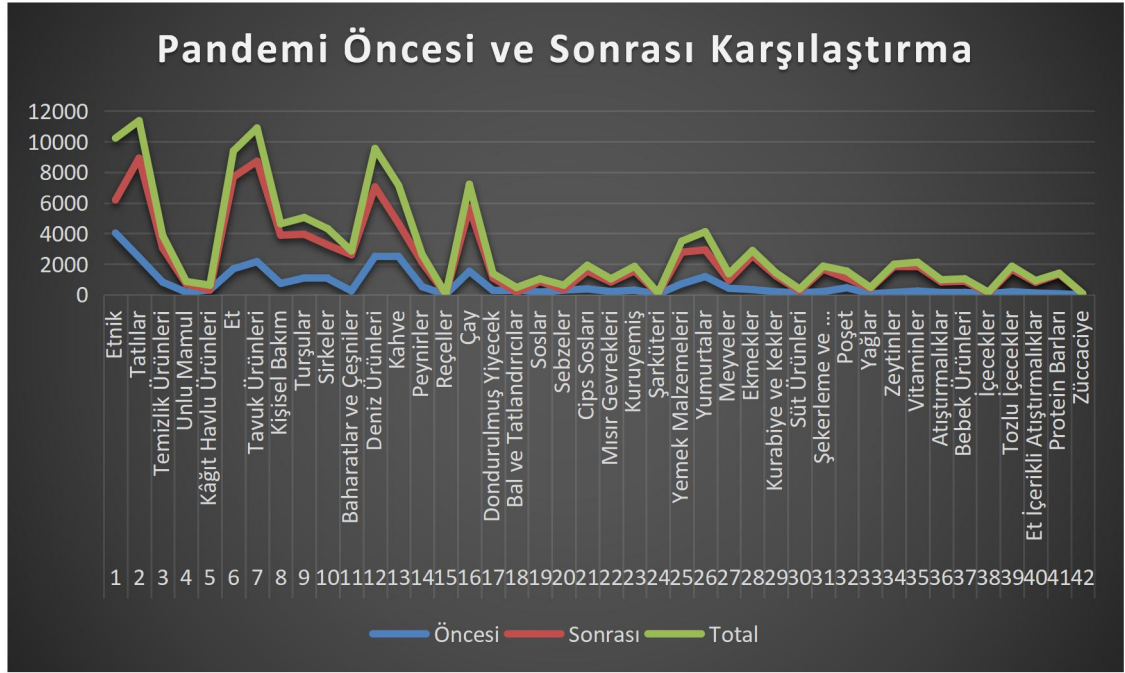
Çizelge 7.5. (devam ediyor).

39	Kâğıt Havlu Ürünleri	203	0,01	1663	0,02
40	Turşular	113	0	813	0,01
41	Tatlılar	62	0	1346	0,01
42	Etnik	0	0	78	0

Çizelge 7.5'e göre;

- Pandemi öncesi en çok satılan içecekler grubu 4.034 satış adedi ile toplam satışın %14'lük kısmını oluştururken, pandemi sonrasında 6.196 adet satışa ulaşmış ancak toplam satışa oranı %6'ya düşmüştür.
- Pandemi öncesinde 2.508 adet satışla toplam satışın %9'unu oluşturan süt ürünleri, pandemi sonrasında 7.047 adet satışa ulaşmış ancak toplam satışa oranı %7'ye düşmüştür.
- Pandemi öncesinde 2.493 satış adedi ile en çok satılan ürün grubu arasında yer alan atıştırmalıklar toplam satışın %9'unu oluştururken, pandemi sonrasında 4.656 adet satışa ulaşmış olsa da toplam satışa oranı %4'e düşmüştür.
- Pandemi öncesinde 1.699 adet satışla toplam satışın %6'sını oluşturan dondurulmuş ürünler, pandemi sonrasında 7.696 adet satışa ulaşmış olup toplam satış oranı %7'ye yükselmiştir.
- Pandemi öncesinde 338 adet satışla toplam satışın %1'ini oluşturan kişisel bakım ürünleri, pandemi sonrasında 2.550 adet satışa ulaşmış olup toplam satış oranı %3'e yükselmiştir.
- Pandemi öncesinde 154 adet satışla toplam satışın %1'ini oluşturan temizlik ürünleri, pandemi sonrasında 1.841 adet satışa ulaşmış olup toplam satış oranı %2'ye yükselmiştir.

- Pandemi öncesinde 203 adet satışla toplam satışın 1%'ini oluşturan kâğıt havlu ürünleri, pandemi sonrasında 1.663 adet satışa ulaşmış olup toplam satış oranı 2%'ye yükselmiştir.
- Pandemi öncesi döneme göre, pandemi sonrası dönemde meyve, sebze, yumurta, peynirler ve kahve gibi ürün gruplarının satışlarında artış olmuştur ancak, ürün gruplarının toplam satışa olan oranlarında bir değişiklik olmamıştır.



Şekil 7.1. Pandemi öncesi ve sonrası alınan ürünler.

Çizelge 7.5'te gösterilen ve bulguları açıklanan Covid-19 öncesi ve Covid-19 sonrası ürünlerin satış adetleri ve bu adetlerin pandemi öncesi ile pandemi sonrası toplam satışa oranlarının çizgi grafiği Şekil 7.1'de verilmiştir. Çizgi grafiğinden, pandemi sonrasında tüm ürün gruplarının satış miktarlarındaki artış görülmektedir.

7.3. HİPOTEZ TEST BULGULARI

7.3.1. Normallik Testi

Pandemi öncesi ve sonrası müşterilerin alışveriş ürünleri arasında farklılık olup olmadığının tespitinde çıkarımsal istatistiklerden (Hipotez testi) yararlanılmıştır. Araştırmada elde edilen verilerin analizinde parametrik veya parametrik olmayan istatistiksel tekniklere karar verebilmek için verilerin öncelikle normallik testi yapılması gerekmektedir. Normallik test sonuçları çizelge 7.6’da verilmiştir.

Çizelge 7.6. Normallik testi.

Tests of Normality						
	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
Pandemi_Öncesi	0,268	42	0,000	0,712	42	0,000
Pandemi_Sonrası	0,195	42	0,000	0,819	42	0,000
a. Lilliefors Significance Correction						

Normallik test sonucuna göre sig. değeri %0,05’ten küçük olduğu için ($p=0,00<0,05$) Mann Whitney testi uygulanmıştır.

7.3.2. Mann Whitney U Testi

Pandemi öncesi ve sonrası müşterilerin alışveriş ürünleri arasında farklılık araştırmasında parametrik olmayan istatistiksel yöntemlerden Mann Whitney U testinden yararlanılmıştır. Hipotez bulguları aşağıda verilmiştir.

H_0 = Covid-19 pandemisi öncesi ve Covid-19 pandemisi sonrası satışlar arasında fark yoktur.

H_s = Covid-19 pandemisi öncesi ve Covid-19 pandemisi sonrası satışlar arasında fark vardır.

Mann-Whitney test sonuçları Çizelge 7.7’de verilmiştir.

Çizelge 7.7. Mann-Whitney U test sonuçları.

Test Statistics ^a	
	Miktar
Mann-Whitney U	410,500
Wilcoxon W	1313,500
Z	-4,218
Asymp. Sig. (2-tailed)	0,000
a. Grouping Variable: Grup	

Mann-Whitney test sonucuna göre sig. değeri 0,05’ten küçük olduğu için ($p=0,00<0,05$) H_0 hipotezi kabul edilmemiştir. Covid-19 pandemisi öncesi ve covid-19 pandemisi sonrası market ürün satışları arasında fark vardır.

7.3.3. Pandemi Öncesi ve Pandemi Sonrası Yüzdesele Değişim

Pandemi öncesi ve sonrası müşterilerin market ürün alışverişlerinin yüzdesele değişimleri çizelge 7.8’de verilmiştir.

Çizelge 7.8. Pandemi öncesi ve sonrası yüzdesele değişim.

	Ürün	Öncesi	Sonrası	Yüzdesele Değişim%
1	Etnik	1	78	7700
2	Tatlılar	62	1346	2071
3	Temizlik Ürünleri	154	1841	1095
4	Unlu Mamul	252	2613	937
5	Kâğıt Havlu Ürünleri	203	1663	719
6	Et	207	1664	704
7	Tavuk Ürünleri	245	1882	668
8	Kişisel Bakım	338	2550	654
9	Turşular	113	813	619
10	Sirkeler	64	416	550
11	Baharatlar ve Çeşniler	196	1227	526
12	Deniz Ürünleri	148	836	465

Çizelge 7.8. (devam ediyor).

13	Kahve	158	884	459
14	Peynirler	740	3892	426
15	Reçeller	301	1556	417
16	Çay	178	870	389
17	Dondurulmuş Yiyecek	1699	7696	353
18	Bal ve Tatlandırıcılar	168	701	317
19	Soslar	383	1545	303
20	Sebzeler	2166	8724	303
21	Cips Sosları	523	2096	301
22	Mısır Gevrekleri	209	834	299
23	Kuruyemiş	718	2780	287
24	Şarküteri	285	1103	287
25	Yemek Malzemeleri	1536	5680	270
26	Yumurtalar	825	3046	269
27	Meyveler	2442	8926	266
28	Ekmekler	1096	3952	261
29	Kurabiye ve Kekler	1058	3252	207
30	Süt Ürünleri	2508	7047	181
31	Şekerleme ve Çikolatalar	1188	2931	147
32	Poşet	12	29	142
33	Yağlar	457	1086	138
34	Zeytinler	422	956	127
35	Vitaminler	124	254	105
36	Atıştırmalıklar	2493	4656	87
37	Bebek Ürünleri	65	107	65
38	İçecekler	4034	6196	54
39	Tozlu İçecekler	49	64	31
40	Et İçerikli Atıştırmalıklar	296	330	11
41	Protein Barları	317	309	-3
42	Züccaciye	320	155	-52

Pandemiden önce 1 adet satılan etnik ürünler, pandeminin etkisinden sonra, 78 adet satmıştır ve etnik ürün satın alan müşterilerin sayısı %7700 artmıştır. Pandemiden önce 62 adet satılan tatlı grubu, pandemiden sonra, 1346 adet satmıştır ve etnik ürün satın alan müşterilerin sayısı %2170 artmıştır. Pandemiden önce 320 adet satılan züccaciye ürünleri, pandemiden sonra, 155 adet satmıştır ve züccaciye ürünü satın alan müşterilerin sayısı %49 azalmıştır. Çizelge 10'da bulunan veriler, pandemi döneminde tüketicilerin züccaciye ürünleri ve protein Barlarına olan eğilimlerinde düşüş olduğunu göstermektedir. Pandemi öncesi en çok satılan ürün grubu süt ürünleri iken, pandemi sonra tüketicilerin daha çok meyve ve sebze alımına yöneldiği görülmektedir.

7.4. VERİ MADENCİLİĞİ BULGULARI

7.4.1. Uygulamada Kullanılan Teknolojiler

Pandemi öncesi ve sonrası müşterilerin market alışveriş ürünlerinin birlikte görülme olasılıklarının araştırılmasında veri madenciliği birliktelik kurallarından yararlanılmıştır. Birliktelik kuralları bulunması sürecinde çalışmada sırasıyla; Microsoft Excel, Python, IBM SPSS Statistics, IBM SPSS Modeler ve Microsoft Word programları kullanılmıştır.

7.4.2. Veri Madenciliği Süreçleri

Pandemi öncesi ve sonrası müşterilerin alışveriş sepetlerindeki ürünlere ilişkin birliktelik kuralları tespiti sürecinde veri madenciliği aşamaları aşağıda detaylı olarak anlatılmıştır. Bu bölüm veri setinin oluşturulması, veri setinin temizlenmesi ve verilerin dönüştürülmesi süreçlerinden oluşmaktadır.

7.4.2.1. Veri Setinin Oluşturulması

Bu çalışmada perakendecilik sektöründe faaliyet gösteren bir işletmenin 20.10.2019 ve 20.08.2020 tarihleri arasındaki satış verileri incelenmiştir. Bu satış verileri üzerinde birliktelik kuralları Apriori Algoritması kullanılarak bir değerlendirme yapılmıştır. On aylık satış verilerinden oluşan bu veri setinde toplam 213.455 örneklem bulunmaktadır. Satış verileri .csv uzantılı olarak elde edilmiştir. Bu veriler öncelikle Python yazılım dili kullanılarak, uygun kod yazılmış, ardından .xls (Microsoft Office Excel) formatına dönüştürülmüştür. Daha sonra, IBM SPSS paket programının Modeler modulünde veri seti olarak kullanılabilmesi için, IBM SPSS Statistics paket programında .sav formatına çevrilmiştir.

7.4.2.2. Veri Setinin Temizlenmesi

Bu aşamada ham veri incelenerek, anlamsız ve hatalı veriler temizlenmiştir. Artık satışı olmayan ürünler ve marketin içerisinde bulunan kafeden yapılan satışlar veri setine dahil edilmemiş olup, çıkartılmıştır. Deneme amaçlı kasadan geçirilen ürünler de aynı şekilde veri setinden çıkartılmış olup, gerekli sadeleştirme yapılmıştır. Satın alınan ürünler için ilgili kategori 1, satın alınmayan ürünler için 0 olarak belirlenmiş ve aynı müşterilerin alışverişleri birleştirilmiştir. Böylelikle, 213.455 örneklem yapılan birleştirmelerle 37.329 adete indirgenmiştir. Bu indirgeme sonucunda veri setinde bir kayıp olmamakla birlikte, yapılacak olan uygulamadan anlamlı bir sonuca ulaşılması amaçlanmıştır. Bu işlemler Python programlama diliyle yazılan kodlarla gerçekleştirilmiştir. Son durumda, elde edilen toplam 37.329 örneklem, 42 farklı nitelikten oluşmaktadır. Bu veri setinin bölünmesi ile birlikte, 20.10.2019-10.03.2020 tarihleri arasındaki veriler pandemi öncesi satışları ve 11.03.2020-19.08.2020 tarihleri arasındaki veriler ise pandemi sonrası satışları oluşturmuştur.

7.4.2.3. Verilerin Dönüşüm Süreci


Ham olarak elde edilen .csv uzantılı veriler öncelikle python programı kullanılarak 0,1 (Satın alınmayan ve satın alınan ürün kategorisi) formatına dönüştürülmüştür. Sonraki aşamada ise veriler, önce .xls (Microsoft Office Excel) formatına, ardından IBM SPSS istatistik programının Modeller modülünde kullanılmak üzere .sav formatına çevrilmiştir.

7.5. MARKET SEPET ANALİZİ UYGULAMASI

7.5.1. Apriori Algoritması ile Pandemi Öncesi Satışların Analizi

7.5.1.1. Model

Veri seti kullanılarak oluşturulan modelin ara yüzü Şekil 7.2'de verilmiştir.



Şekil 7.2. Apriori Algoritması ile IBM SPSS Modeler birliktelik kuralları modeli 1.

Bu çalışmada müşterilerin pandemi öncesi ve sonrasındaki market ürün alışverişleri incelenmiş ve ürünlerin birlikte görülme olasılıkları ortaya çıkarılmıştır. Modelde apriori algoritması kullanılmıştır. Filtre bölümünde müşteri sayısı ve alışveriş tarihi kapsam dışı bırakılmıştır. Model kurulumunda, minimum güvenilirlik değeri %100, minimum birlikte gerçekleşme değeri ise %0,05 olarak alınmıştır.

7.5.1.2. Veri Madenciliği Sonuçları

Modelin çıktısında, belirlenen kriterlere uygun olarak 52 farklı sonuç yer almıştır. Sonuçlar Çizelge 7.9'da verilmiştir.

Çizelge 7.9. Apriori algoritması ile pandemi öncesi bulunan birliktelik kuralları.

Consequent	Antecedent	Support %	Confidence %
Sebzeler	Deniz Ürünleri ve Tavuk Ürünleri	0,050	100
Atıştırmalıklar	Tozlu İçecekler ve Kurabiye ve Kekler ve İçecekler	0,050	100
Yemek Malzemeleri	Turşular ve Kurabiye ve Kekler ve Süt Ürünleri	0,050	100
Sebzeler	Temizlik Ürünleri ve Deniz Ürünleri ve Meyveler	0,050	100
Sebzeler	Temizlik Ürünleri ve Tavuk Ürünleri ve Meyveler	0,050	100
Meyveler	Çay ve Kuruyemiş ve Sebzeler	0,050	100
Peynirler	Bal ve Tatlandırıcılar ve Zeytinler ve Kuruyemiş	0,050	100
Süt Ürünleri	Bal ve Tatlandırıcılar ve Kurabiye ve Kekler ve Atıştırmalıklar	0,057	100
Meyveler	Mısır Gevrekleri ve Kuruyemiş ve Atıştırmalıklar	0,057	100
İçecekler	Deniz Ürünleri ve Cips sosları ve Dondurulmuş Yiyecek	0,050	100
Sebzeler	Et ve Tavuk Ürünleri ve Peynirler	0,050	100
Sebzeler	Et ve Soslar ve İçecekler	0,050	100
Sebzeler	Unlu Mamul ve Tavuk Ürünleri ve Meyveler	0,057	100
Süt Ürünleri	Unlu Mamul ve Yağlar ve Meyveler	0,050	100
Meyveler	Unlu Mamul ve Kuruyemiş ve Yemek Malzemeleri	0,050	100
Sebzeler	Tavuk Ürünleri ve Kişisel Bakım ve Meyveler	0,050	100
Sebzeler	Tavuk Ürünleri ve Soslar ve Dondurulmuş Yiyecek	0,050	100
Sebzeler	Tavuk Ürünleri ve Soslar ve Meyveler	0,079	100
Meyveler	Tavuk Ürünleri ve Yumurtalar ve Kurabiye ve Kekler	0,050	100
Sebzeler	Tavuk Ürünleri ve Kurabiye ve Kekler ve Ekmekler	0,057	100
Meyveler	Tavuk Ürünleri ve Kurabiye ve Kekler ve Ekmekler	0,057	100
Yemek Malzemeleri	Zeytinler ve Kuruyemiş ve Kurabiye ve Kekler	0,057	100
Dondurulmuş Yiyecek	Reçeller ve Yağlar ve Cips Sosları	0,050	100
Yemek Malzemeleri	Reçeller ve Cips sosları ve Kurabiye ve Kekler	0,057	100
Yemek Malzemeleri	Soslar ve Peynirler ve Kurabiye ve Kekler	0,050	100
Dondurulmuş Yiyecek	Turşular ve Peynirler ve Yemek Malzemeleri ve Süt Ürünleri	0,050	100
Sebzeler	Deniz Ürünleri ve Yumurtalar ve Peynirler ve Meyveler	0,050	100

Çizelge 7.9. (devam ediyor).

Meyveler	Baharatlar ve Çeşniler ve Yumurtalar ve Yemek Malzemeleri ve Dondurulmuş Yiyecek	0,050	100
Meyveler	Baharatlar ve Çeşniler ve Yumurtalar ve Yemek Malzemeleri ve Sebzeler	0,050	100
Yemek Malzemeleri	Baharatlar ve Çeşniler ve Dondurulmuş Yiyecek ve Süt Ürünleri ve Meyveler	0,064	100
Süt Ürünleri	Baharatlar ve Çeşniler ve Yemek Malzemeleri ve Atıştırmalıklar ve Meyveler	0,057	100
Süt Ürünleri	Unlu Mamul ve Kurabiye ve Kekler ve Yemek Malzemeleri ve Dondurulmuş Yiyecek	0,050	100
Meyveler	Tavuk Ürünleri ve Kurabiye ve Kekler ve Ekmekler ve Sebzeler	0,057	100
Sebzeler	Tavuk Ürünleri ve Kurabiye ve Kekler ve Ekmekler ve Meyveler	0,057	100
Sebzeler	Tavuk Ürünleri ve Atıştırmalıklar ve Meyveler ve İçecekler	0,050	100
Meyveler	Kişisel Bakım ve Kuruyemiş ve Yemek Malzemeleri ve Süt Ürünleri	0,050	100
Süt Ürünleri	Kişisel Bakım ve Kuruyemiş ve Sebzeler ve Meyveler	0,057	100
Dondurulmuş Yiyecek	Reçeller ve Cips sosları ve Peynirler ve Süt Ürünleri	0,050	100
Dondurulmuş Yiyecek	Reçeller ve Cips sosları ve Yemek Malzemeleri ve Sebzeler	0,050	100
Sebzeler	Soslar ve Kurabiye ve Kekler ve Yemek Malzemeleri ve Meyveler	0,064	100
Süt Ürünleri	Cips sosları ve Yumurtalar ve Peynirler ve İçecekler	0,057	100
Meyveler	Kuruyemiş ve Yumurtalar ve Dondurulmuş Yiyecek ve Atıştırmalıklar	0,050	100
Meyveler	Kuruyemiş ve Yumurtalar ve Dondurulmuş Yiyecek ve Sebzeler	0,050	100
Meyveler	Kuruyemiş ve Peynirler ve Ekmekler ve Süt Ürünleri	0,050	100
Meyveler	Kuruyemiş ve Peynirler ve Atıştırmalıklar ve Sebzeler	0,050	100
Meyveler	Kuruyemiş ve Ekmekler ve Dondurulmuş Yiyecek ve Süt Ürünleri	0,050	100
Süt Ürünleri	Yumurtalar ve Peynirler ve Kurabiye ve Kekler ve Ekmekler	0,050	100
Süt Ürünleri	Yumurtalar ve Kurabiye ve Kekler ve Ekmekler ve Yemek Malzemeleri	0,050	100
Meyveler	Kurabiye ve Kekler ve Şekerleme ve Çikolatalar ve Dondurulmuş Yiyecek ve Sebzeler	0,050	100
Süt Ürünleri	Reçeller ve Yemek Malzemeleri ve Dondurulmuş Yiyecek ve Sebzeler ve Meyveler	0,050	100
Süt Ürünleri	Cips sosları ve Dondurulmuş Yiyecek ve Sebzeler ve Meyveler ve İçecekler	0,050	100
Meyveler	Peynirler ve Kurabiye ve Kekler ve Yemek Malzemeleri ve Dondurulmuş Yiyecek ve Sebzeler	0,050	100

7.5.1.3. Apriori Algoritması ile Bulunan Birliktelik Kuralları

Bu çalışmada müşterilerin pandemi öncesi ve sonrasındaki market ürün alışverişleri veri madenciliği birliktelik kurallarından apriori algoritması ile araştırılmış ve %100 olarak bulunan kurallar aşağıda verilmiştir.


- Deniz ürünleri, tavuk ürünleri ve sebzenin birlikte görülme olasılığı % 6'dır. Deniz ürünleri ve tavuk ürünleri satın alan bir müşteri arkasından % 100 olasılıkla sebze satın almıştır.
- Tozlu içecekler, içecekler, kurabiye ve keklerin birlikte görülme olasılığı %6'dır. Tozlu içecekler, içecekler, kurabiye ve kekleri satın alan müşteriler arkasından %100 olasılıkla atıştırmalıklar satın almıştır.
- Turşular, kurabiye, kekler ve süt ürünlerini birlikte görülme olasılığı %5'tir. Turşular, kurabiye, kekler ve süt ürünlerini satın alan müşteriler arkasından %100 olasılıkla yemek malzemeleri satın almıştır.
- Temizlik ürünleri, deniz ürünleri ve meyve'nin birlikte görülme olasılığı %5'tir. Temizlik ürünleri, deniz ürünleri ve meyve satın alan müşteriler arkasından %100 olasılıkla sebze satın almıştır.
- Temizlik ürünleri, meyve ve tavuk ürünlerinin birlikte görülme olasılığı %5'tir. Temizlik ürünleri, meyve ve tavuk ürünlerini satın alan müşteriler arkasından %100 olasılıkla sebze satın almıştır.
- Çay, kuruyemiş ve sebzenin birlikte görülme olasılığı %5'tir. Çay, kuruyemiş ve sebze satın alan müşteriler arkasından %100 olasılıkla meyve satın almıştır.
- Zeytin, kuruyemiş, bal ve tatlandırıcılar birlikte görülme olasılığı %5'tir. Zeytin, kuruyemiş, bal ve tatlandırıcılar satın alan müşteriler arkasından %100 olasılıkla peynir satın almıştır.

- Kurabiye, kek, atıştırma lıklar, bal ve tatlandırıcılar birlikte görülme olasılığı %5'tir. Kurabiye, kek, atıştırma lıklar, bal ve tatlandırıcılar satın alan müşterileri arkasından %100 olasılıkla süt ürünleri satın almıştır.
- Mısır gevrekleri, kuruyemiş ve atıştırma lıklar birlikte görülme olasılığı %5'tir. Mısır gevrekleri, kuruyemiş ve atıştırma lıklar tatlandırıcılar satın alan müşterileri arkasından %100 olasılıkla meyve satın almıştır.
- Deniz ürünleri, cips sosları ve dondurulmuş yiyecek atıştırma lıklar birlikte görülme olasılığı %5'tir. Deniz ürünleri, cips sosları ve dondurulmuş yiyecek satın alan müşteriler arkasından %100 olasılıkla içecek satın almıştır.

7.5.2. Apriori Algoritması ile Pandemi Sonrası Satışların Analizi

7.5.2.1. Model

Veri seti kullanılarak oluşturulan modelin ara yüzü Şekil 7.3'te verilmiştir.



Şekil 7.3. Apriori Algoritması ile IBM SPSS Modeler birliktelik kuralları modeli 2.

Modelde apriori algoritması kullanmıştır. Filtre bölümünde müşteri sayısı ve alışveriş tarihi kapsam dışı bırakılmıştır. Model kurulumunda, minimum güvenilirlik değeri %100, minimum birlikte gerçekleşme değeri ise %0,05 olarak alınmıştır.

7.5.2.2. Veri Madenciliği Sonuçları

Modelin çıktısında, belirlenen kriterlere uygun olarak 45 farklı sonuç yer almıştır. Sonuçlar çizelge 7.10'da verilmiştir.

Çizelge 7.10. Apriori algoritması ile pandemi sonrası bulunan birliktelik kuralları.

Consequent	Antecedent	Support %	Confidence %
Sebzeler	Yağlar ve Tavuk Ürünleri ve Peynirler ve Yemek Malzemeleri	0,24	100
Sebzeler	Kâğıt Havlu Ürünleri ve Et ve Yumurtalar ve Dondurulmuş Yiyecek	0,30	100
Sebzeler	Kâğıt Havlu Ürünleri ve Tavuk Ürünleri ve Yumurtalar ve Ekmekler	0,25	100
Sebzeler	Soslar ve Tavuk Ürünleri ve Peynirler ve İçecekler	0,24	100
Sebzeler	Reçeller ve Tavuk Ürünleri ve Ekmekler ve İçecekler	0,23	100
Süt Ürünleri	Mısır Gevrekleri ve Unlu Mamul ve Yumurtalar ve Yemek Malzemeleri ve Dondurulmuş Yiyecek	0,26	100
Sebzeler	Kâğıt Havlu Ürünleri ve Et ve Yumurtalar ve Süt Ürünleri ve Dondurulmuş Yiyecek	0,26	100
Sebzeler	Kâğıt Havlu Ürünleri ve Et ve Yumurtalar ve Dondurulmuş Yiyecek ve Meyveler	0,23	100
Sebzeler	Kâğıt Havlu Ürünleri ve Et ve Ekmekler ve Süt Ürünleri ve Dondurulmuş Yiyecek	0,26	100
Sebzeler	Kâğıt Havlu Ürünleri ve Tavuk Ürünleri ve Yumurtalar ve Ekmekler ve Süt Ürünleri	0,23	100
Sebzeler	Kâğıt Havlu Ürünleri ve Tavuk Ürünleri ve Yumurtalar ve Süt Ürünleri ve Meyveler	0,28	100
Sebzeler	Soslar ve Et ve Peynirler ve Süt Ürünleri ve Dondurulmuş Yiyecek	0,24	100
Sebzeler	Soslar ve Tavuk Ürünleri ve Yumurtalar ve Ekmekler ve Süt Ürünleri	0,25	100
Sebzeler	Soslar ve Tavuk Ürünleri ve Yumurtalar ve Peynirler ve Süt Ürünleri	0,28	100
Sebzeler	Soslar ve Tavuk Ürünleri ve Yumurtalar ve Peynirler ve Meyveler	0,24	100
Sebzeler	Soslar ve Tavuk Ürünleri ve Peynirler ve İçecekler ve Süt Ürünleri	0,23	100
Sebzeler	Soslar ve Tavuk Ürünleri ve Peynirler ve Süt Ürünleri ve Dondurulmuş Yiyecek	0,34	100
Sebzeler	Soslar ve Tavuk Ürünleri ve Peynirler ve Dondurulmuş Yiyecek ve Meyveler	0,33	100
Sebzeler	Et ve Tavuk Ürünleri ve Yumurtalar ve Ekmekler ve Peynirler	0,33	100
Sebzeler	Et ve Tavuk Ürünleri ve Yumurtalar ve Atıştırmalıklar ve Peynirler	0,25	100
Sebzeler	Et ve Tavuk Ürünleri ve Ekmekler ve Atıştırmalıklar ve Peynirler	0,27	100
Süt Ürünleri	Et ve Tavuk Ürünleri ve Ekmekler ve Peynirler ve İçecekler	0,29	100
Süt Ürünleri	Et ve Cips sosları ve Yumurtalar ve Peynirler ve Dondurulmuş Yiyecek	0,24	100
Süt Ürünleri	Et ve Unlu Mamul ve Yumurtalar ve İçecekler ve Dondurulmuş Yiyecek	0,23	100

Çizelge 7.10. (devam ediyor).

Sebzeler	Et ve Yumurtalar ve Kurabiye ve Kekler ve İçecekler ve Süt Ürünleri	0,25	100
Sebzeler	Et ve Yumurtalar ve Kurabiye ve Kekler ve İçecekler ve Dondurulmuş Yiyecek	0,24	100
Sebzeler	Et ve Kurabiye ve Kekler ve Ekmekler ve İçecekler ve Süt Ürünleri	0,25	100
Sebzeler	Et ve Kurabiye ve Kekler ve Ekmekler ve İçecekler ve Meyveler	0,25	100
Sebzeler	Reçeller ve Tavuk Ürünleri ve Yumurtalar ve Peynirler ve Meyveler	0,26	100
Sebzeler	Reçeller ve Tavuk Ürünleri ve Peynirler ve Dondurulmuş Yiyecek ve Meyveler	0,27	100
Sebzeler	Reçeller ve Tavuk Ürünleri ve İçecekler ve Süt Ürünleri ve Meyveler	0,27	100
Sebzeler	Tavuk Ürünleri ve Cips sosları ve Yumurtalar ve Ekmekler ve Peynirler	0,25	100
Sebzeler	Tavuk Ürünleri ve Cips sosları ve Yumurtalar ve Peynirler ve Yemek Malzemeleri	0,25	100
Sebzeler	Tavuk Ürünleri ve Unlu Mamul ve Yumurtalar ve Ekmekler ve Peynirler	0,26	100
Sebzeler	Tavuk Ürünleri ve Unlu Mamul ve Ekmekler ve Peynirler ve İçecekler	0,24	100
Sebzeler	Tavuk Ürünleri ve Unlu Mamul ve Ekmekler ve Peynirler ve Dondurulmuş Yiyecek	0,31	100
Sebzeler	Tavuk Ürünleri ve Kuruyemiş ve Ekmekler ve Peynirler ve Süt Ürünleri	0,23	100
Sebzeler	Tavuk Ürünleri ve Yumurtalar ve Kurabiye ve Kekler ve Ekmekler ve Peynirler	0,25	100
Sebzeler	Tavuk Ürünleri ve Yumurtalar ve Kurabiye ve Kekler ve Peynirler ve İçecekler	0,24	100
Sebzeler	Tavuk Ürünleri ve Yumurtalar ve Ekmekler ve Peynirler ve İçecekler	0,34	100
Sebzeler	Tavuk Ürünleri ve Yumurtalar ve Ekmekler ve Peynirler ve Yemek Malzemeleri	0,45	100
Sebzeler	Tavuk Ürünleri ve Yumurtalar ve Ekmekler ve Peynirler ve Meyveler	0,54	100
Sebzeler	Tavuk Ürünleri ve Kurabiye ve Kekler ve Ekmekler ve Peynirler ve Meyveler	0,33	100
Sebzeler	Tavuk Ürünleri ve Kurabiye ve Kekler ve Ekmekler ve İçecekler ve Meyveler	0,28	100
Sebzeler	Tavuk Ürünleri ve Kurabiye ve Kekler ve Peynirler ve İçecekler ve Meyveler	0,28	100

7.5.2.3. Bulgular

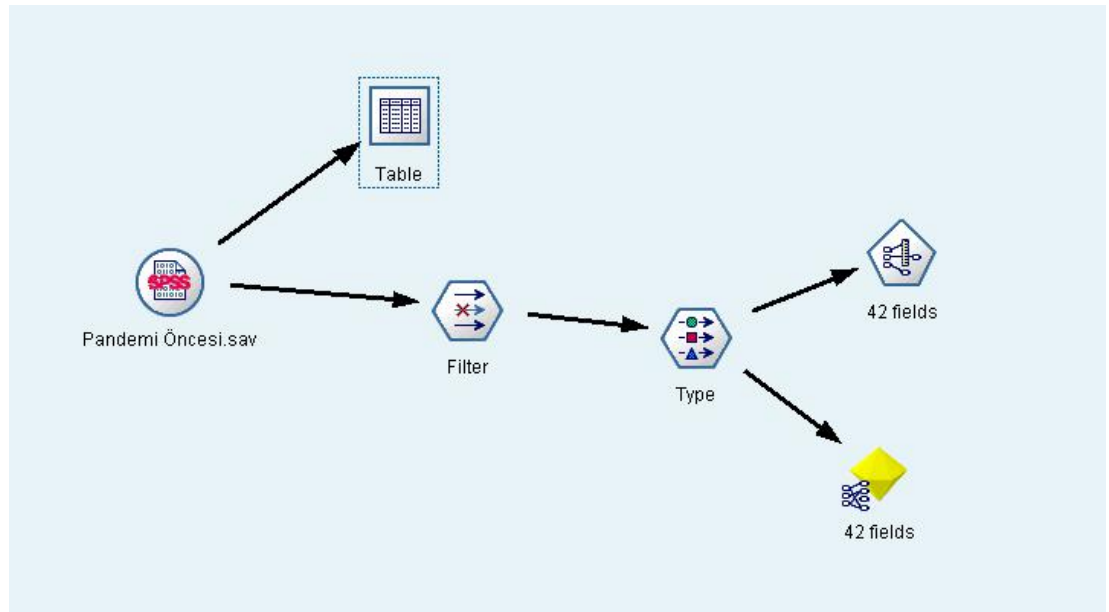
- Yağ, peynir, yemek malzemeleri ve tavuk ürünlerinin birlikte görülme olasılığı %24'tür. Yağ, peynir, yemek malzemeleri ve tavuk ürünlerini ürünleri satın alan bir müşteri arkasından %100 olasılıkla sebze satın almıştır.
- Kâğıt havlu ürünleri, et, yumurta ve dondurulmuş yiyecek birlikte görülme olasılığı %30'dur. Kâğıt havlu ürünleri, et, yumurta ve dondurulmuş yiyecek satın alan bir müşteri arkasından %100 olasılıkla sebze satın almıştır.
- Kâğıt havlu ürünleri, tavuk ürünleri, yumurta ve ekmek birlikte görülme olasılığı %30'dur. Kâğıt havlu ürünleri, tavuk ürünleri, yumurta ve ekmek satın alan bir müşteri arkasından %100 olasılıkla sebze satın almıştır.
- Soslar, tavuk ürünleri, yumurta ve ekmek birlikte görülme olasılığı %25'tir. Soslar, tavuk ürünleri, yumurta ve ekmek satın alan bir müşteri arkasından %100 olasılıkla sebze satın almıştır.
- Reçel, ekmek, içecek ve tavuk ürünlerini birlikte görülme olasılığı %23'tür. Reçel, ekmek, içecek ve tavuk ürünlerini satın alan bir müşteri arkasından %100 olasılıkla sebze satın almıştır.
- Et, ekmek, peynir, içecek ve tavuk ürünlerini birlikte görülme olasılığı %29'dur. Et, ekmek, peynir, içecek ve tavuk ürünlerini satın alan bir müşteri arkasından %100 olasılıkla süt ürünleri satın almıştır.
- Et, cips sosları, yumurta, peynir ve dondurulmuş yiyecek birlikte görülme olasılığı %24'tür. Et, cips sosları, yumurta, peynir ve dondurulmuş yiyecek satın alan bir müşteri arkasından %100 olasılıkla sebze satın almıştır.

- Et, unlu mamul, yumurta, içecek ve dondurulmuş yiyecek birlikte görülme olasılığı %23'tür. Et, unlu mamul, yumurta, içecek ve dondurulmuş yiyecek satın alan bir müşteri arkasından %100 olasılıkla sebze satın almıştır.
- Reçel, tavuk ürünleri, yumurta, peynir ve meyve birlikte görülme olasılığı %26'dır. Reçel, tavuk ürünleri, yumurta, peynir ve meyve satın alan bir müşteri arkasından %100 olasılıkla sebze satın almıştır.
- Tavuk ürünleri, cips sosları, yumurta, ekmek ve peynir birlikte görülme olasılığı %25'tir. Tavuk ürünleri, cips sosları, yumurta, ekmek ve peynir satın alan bir müşteri arkasından %100 olasılıkla sebze satın almıştır.

7.5.3. GRI Algoritması ile Pandemi Öncesi Satışların Analizi

7.5.3.1. Model

Veri seti kullanılarak oluşturulan modelin ara yüzü Şekil 7.4'te verilmiştir.



Şekil 7.4. GRI Algoritması ile IBM SPSS Modeler birliktelik kuralları modeli 1.

Modelde GRI algoritması kullanılmıştır. Filtre bölümünde müşteri sayısı ve alışveriş tarihi kapsam dışı bırakılmıştır. Model kurulumunda, minimum güvenilirlik değeri %100, minimum birlikte gerçekleşme değeri ise %0,02 olarak alınmıştır.

7.5.3.2. Veri Madenciliği Sonuçları

Modelin çıktısında, belirlenen kriterlere uygun olarak 100 farklı sonuç yer almıştır. Sonuçlar Çizelge 7.11’de verilmiştir.

Çizelge 7.11. GRI algoritması ile pandemi öncesi bulunan birliktelik kuralları.

Consequent	Antecedent	Support %	Confidence %
Bal ve Tatlandırıcılar	Peynirler ve Reçeller ve Zeytinler	0,04	100
Peynirler	Bal ve Tatlandırıcılar ve Kuruyemiş ve Zeytinler	0,05	100
Sebzeler	Meyveler ve Soslar ve Tavuk ürünleri	0,08	100
Unlu Mamul	Sebzeler ve Süt ürünleri ve Tatlılar	0,04	100
Cips sosları	Dondurulmuş Yiyecek ve Reçeller ve Zeytinler	0,04	100
Deniz ürünleri	Züccaciye ve Temizlik ürünleri	0,03	100
Kahve	Yumurtalar ve Ekmekler ve Et İçerikli Atıştırmalıklar	0,03	100
Kuruyemiş	Dondurulmuş Yiyecek ve Kurabiye ve Kekler ve Et İçerikli Atıştırmalıklar	0,04	100
Kuruyemiş	Meyveler ve Zeytinler ve Yağlar	0,04	100
Bal ve Tatlandırıcılar	Reçeller ve Zeytinler ve Turşular	0,03	100
Yemek Malzemeleri	Kurabiye ve Kekler ve Kuruyemiş ve Zeytinler	0,06	100
Yemek Malzemeleri	Kurabiye ve Kekler ve Cips sosları ve Reçeller	0,06	100
Peynirler	Bal ve Tatlandırıcılar ve Reçeller ve Yağlar	0,04	100
Peynirler	Bal ve Tatlandırıcılar ve Cips sosları ve Reçeller	0,04	100
Peynirler	Meyveler ve Bal ve Tatlandırıcılar ve Cips sosları	0,04	100
Yağlar	Sebzeler ve Reçeller ve Baharatlar ve Çeşniler	0,04	100
Tozlu İçecekler	Cips sosları ve Et İçerikli Atıştırmalıklar ve Kahve	0,02	100
Tozlu İçecekler	Peynirler ve Et İçerikli Atıştırmalıklar ve Kahve	0,02	100
Tozlu İçecekler	Peynirler ve Cips sosları ve Kahve	0,02	100
Tozlu İçecekler	Yumurtalar ve Cips sosları ve Kahve	0,02	100
Sebzeler	Tavuk ürünleri ve Deniz ürünleri	0,06	100
Sirkeler	Süt ürünleri ve Yağlar ve Turşular	0,02	100
Sirkeler	Dondurulmuş Yiyecek ve Cips sosları ve Züccaciye	0,02	100
Kurabiye ve Kekler	Atıştırmalıklar ve Şekerleme ve Çikolatalar ve Tatlılar	0,04	100

Çizelge 7.11. (devam ediyor).

Yemek Malzemeleri	Kurabiye ve Kekler ve Süt ürünleri ve Turşular	0,05	100
Yemek Malzemeleri	Peynirler ve Kurabiye ve Kekler ve Soslar	0,05	100
Et İçerikli Atıştırmalıklar	Tozlu İçecekler ve Kahve	0,03	100
Et İçerikli Atıştırmalıklar	Atıştırmalıklar ve Tozlu İçecekler ve Kahve	0,03	100
Reçeller	Cips sosları ve Kuruyemiş ve Zeytinler	0,03	100
Reçeller	Bal ve Tatlandırıcılar ve Zeytinler ve Yağlar	0,03	100
Reçeller	Bal ve Tatlandırıcılar ve Cips sosları ve Zeytinler	0,03	100
Ekmekler	Süt ürünleri ve Cips sosları ve Kahve	0,04	100
Ekmekler	Peynirler ve Cips sosları ve Deniz ürünleri	0,04	100
Sebzeler	Ekmekler ve Kurabiye ve Kekler ve Tavuk ürünleri	0,06	100
Sebzeler	Meyveler ve Unlu Mamul ve Tavuk ürünleri	0,06	100
Şekerleme ve Çikolatalar	Et İçerikli Atıştırmalıklar ve Mısır Gevrekleri	0,04	100
Dondurulmuş Yiyecek	Cips sosları ve Reçeller ve Yağlar	0,05	100
Peynirler	Kuruyemiş ve Zeytinler ve Turşular	0,04	100
Peynirler	Kuruyemiş ve Şekerleme ve Çikolatalar ve Sirkeler	0,04	100
Peynirler	Yemek Malzemeleri ve Şekerleme ve Çikolatalar ve Sirkeler	0,04	100
Peynirler	Dondurulmuş Yiyecek ve Zeytinler ve Turşular	0,04	100
Peynirler	Bal ve Tatlandırıcılar ve Zeytinler ve Turşular	0,04	100
Peynirler	Bal ve Tatlandırıcılar ve Kurabiye ve Kekler ve Cips sosları	0,04	100
Peynirler	Bal ve Tatlandırıcılar ve Dondurulmuş Yiyecek ve Turşular	0,04	100
Peynirler	Bal ve Tatlandırıcılar ve Dondurulmuş Yiyecek ve Yağlar	0,04	100
Peynirler	Bal ve Tatlandırıcılar ve Dondurulmuş Yiyecek ve Zeytinler	0,04	100
Peynirler	Yumurtalar ve Kuruyemiş ve Zeytinler	0,04	100
Peynirler	İçecekler ve Cips sosları ve Yağlar	0,04	100
Turşular	Bal ve Tatlandırıcılar ve Reçeller ve Tatlılar	0,02	100
Zeytinler	Meyveler ve Yağlar ve Sirkeler	0,03	100

Çizelge 7.11. (devam ediyor).

Meyveler	Atıştırmalıklar ve Mısır Gevrekleri ve Kuruyemiş	0,06	100
Meyveler	Ekmekler ve Kurabiye ve Kekler ve Tavuk ürünleri	0,06	100
Süt ürünleri	Bal ve Tatlandırıcılar ve Kurabiye ve Kekler ve Atıştırmalıklar	0,06	100
Yağlar	Süt ürünleri ve Zeytinler ve Sirkeler	0,03	100
Yağlar	Peynirler ve Cips sosları ve Sirkeler	0,03	100
Yağlar	Meyveler ve Zeytinler ve Sirkeler	0,03	100
Deniz ürünleri	Yemek Malzemeleri ve Züccaciye ve Temizlik ürünleri	0,02	100
Deniz ürünleri	Cips sosları ve Yemek Malzemeleri ve Mısır Gevrekleri	0,02	100
Deniz ürünleri	Ekmekler ve Cips sosları ve Turşular	0,02	100
Deniz ürünleri	Sebzeler ve Züccaciye ve Temizlik ürünleri	0,02	100
Deniz ürünleri	Dondurulmuş Yiyecek ve Kişisel Bakım ve Turşular	0,02	100
Deniz ürünleri	Meyveler ve Züccaciye ve Temizlik ürünleri	0,02	100
Deniz ürünleri	İçecekler ve Cips sosları ve Mısır Gevrekleri	0,02	100
Temizlik ürünleri	Sebzeler ve Züccaciye ve Deniz ürünleri	0,02	100
Temizlik ürünleri	Meyveler ve Züccaciye ve Deniz ürünleri	0,02	100
Kahve	Cips sosları ve Et İçerikli Atıştırmalıklar ve Tozlu İçecekler	0,02	100
Kahve	Kurabiye ve Kekler ve Cips sosları ve Tozlu İçecekler	0,02	100
Kahve	Ekmekler ve Et İçerikli Atıştırmalıklar ve Tozlu İçecekler	0,02	100
Kahve	Ekmekler ve Atıştırmalıklar ve Tozlu İçecekler	0,02	100
Kahve	Ekmekler ve Süt ürünleri ve Tozlu İçecekler	0,02	100
Kahve	Ekmekler ve Kurabiye ve Kekler ve Tozlu İçecekler	0,02	100
Kahve	Peynirler ve Et İçerikli Atıştırmalıklar ve Tozlu İçecekler	0,02	100
Kahve	Peynirler ve Süt ürünleri ve Tozlu İçecekler	0,02	100
Kahve	Sebzeler ve Et İçerikli Atıştırmalıklar ve Tozlu İçecekler	0,02	100
Kahve	Sebzeler ve Ekmekler ve Tozlu İçecekler	0,02	100
Kahve	Sebzeler ve Peynirler ve Tozlu İçecekler	0,02	100

Çizelge 7.11. (devam ediyor).

Kahve	Yumurtalar ve Et İçerikli Atıştırmalıklar ve Tozlu İçecekler	0,02	100
Kahve	Yumurtalar ve Cips sosları ve Tozlu İçecekler	0,02	100
Kahve	Yumurtalar ve Atıştırmalıklar ve Tozlu İçecekler	0,02	100
Kahve	Yumurtalar ve Peynirler ve Tozlu İçecekler	0,02	100
Bal ve Tatlandırıcılar	Zeytinler ve Turşular ve Tatlılar	0,02	100
Bal ve Tatlandırıcılar	Zeytinler ve Yağlar ve Turşular	0,02	100
Bal ve Tatlandırıcılar	Reçeller ve Turşular ve Tatlılar	0,02	100
Bal ve Tatlandırıcılar	Reçelle ve Yağlar ve Turşular	0,02	100
Bal ve Tatlandırıcılar	Reçeller ve Zeytinler ve Sirkeler	0,02	100
Bal ve Tatlandırıcılar	Yemek Malzemeleri ve Turşular ve Tatlılar	0,02	100
Bal ve Tatlandırıcılar	Cips sosları ve Zeytinler ve Sirkeler	0,02	100
Bal ve Tatlandırıcılar	Kurabiye ve Kekler ve Mısır Gevrekleri ve Kişisel Bakım	0,02	100
Bal ve Tatlandırıcılar	Kurabiye ve Kekler ve Zuccaciye ve Kişisel Bakım	0,02	100
Bal ve Tatlandırıcılar	Peynirler ve Yağlar ve Turşular	0,02	100
Bal ve Tatlandırıcılar	Dondurulmuş Yiyecek ve Yağlar ve Sirkeler	0,02	100
Bal ve Tatlandırıcılar	Meyveler ve Turşular ve Tatlılar	0,02	100
Yemek Malzemeleri	Kurabiye ve Kekler ve Reçeller ve Zeytinler	0,04	100
Yemek Malzemeleri	Peynirler ve Soslar ve Tavuk ürünleri	0,04	100
Yemek Malzemeleri	Peynirler ve Kurabiye ve Kekler ve Çay	0,04	100
Yemek Malzemeleri	Peynirler ve Ekmekler ve Mısır Gevrekleri	0,04	100
Yemek Malzemeleri	Sebzeler ve Soslar ve Deniz ürünleri	0,04	100
Yemek Malzemeleri	Dondurulmuş Yiyecek ve Ekmekler ve Mısır Gevrekleri	0,04	100
Yemek Malzemeleri	Bal ve Tatlandırıcılar ve Kurabiye ve Kekler ve Zeytinler	0,04	100
Yemek Malzemeleri	Yumurtalar ve Kuruyemişve Yağlar	0,04	100

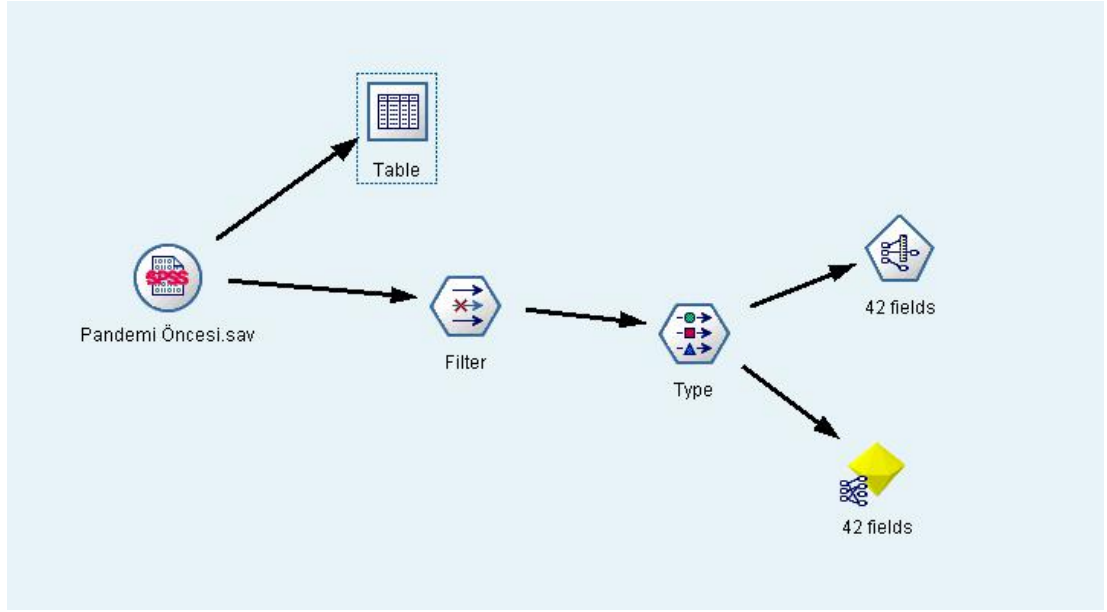
7.5.3.3. Bulgular

- Bal ve tatlandırıcılar, kurutemiş ve zeytin olasılığı %5'tir. Bal ve tatlandırıcılar, kuruyemiş ve zeytin satın alan müşteri arkasından %100 olasılıkla peynir satın almıştır.
- Peynir, reçel ve zeytin birlikte görülme olasılığı %4'tür. Peynir, reçel ve zeytin satın alan bir müşteri arkasından %100 olasılıkla bal ve tatlandırıcı satın almıştır.
- Meyve, soslar ve tavuk ürünleri görülme olasılığı %8'dir. Meyve, soslar ve tavuk ürünleri satın alan müşteri arkasından %100 olasılıkla sebze satın almıştır.
- Sebze, tatlı ve süt ürünleri görülme olasılığı %4'tür. Sebze, tatlı ve süt ürünleri satın alan müşteri arkasından %100 olasılıkla unlu mamul satın almıştır.
- Dondurulmuş yiyecek, reçel ve zeytin görülme olasılığı %4'tür. Dondurulmuş yiyecek, reçel ve zeytin satın alan müşteri arkasından %100 olasılıkla cips sosları satın almıştır.
- Züccaciye ve temizlik ürünleri görülme olasılığı %3'tür. Züccaciye ve temizlik ürünleri satın alan müşteriler arkasından %100 olasılıkla deniz ürünleri satın almıştır.
- Yumurta, ekmek ve et içerikli atıştırmalıklar görülme olasılığı %3'tür. Yumurta, ekmek ve et içerikli atıştırmalıklar satın alan müşteriler arkasından %100 olasılıkla kahve satın almıştır.
- Dondurulmuş yiyecek, et içerikli atıştırmalıklar, kurabiye ve kekler görülme olasılığı %3'tür. Dondurulmuş yiyecek, et içerikli atıştırmalıklar, kurabiye ve kekler satın alan müşteriler arkasından %100 olasılıkla kuruyemiş satın almıştır.

7.5.4. GRI Algoritması ile Pandemi Sonrası Satışların Analizi

7.5.4.1. Model

Veri seti kullanılarak oluşturulan modelin ara yüzü Şekil 7.5'te verilmiştir.



Şekil 7.5. GRI Algoritması ile IBM SPSS Modeler birliktelik kuralları modeli 2.

Modelde GRI algoritması kullanılmıştır. Filtre bölümünde müşteri sayısı ve alışveriş tarihi kapsam dışı bırakılmıştır. Model kurulumunda, minimum güvenilirlik değeri %100, minimum birlikte gerçekleşme değeri ise %0,02 olarak alınmıştır.

7.5.4.2. Veri Madenciliği Sonuçları

Modelin çıktısında, belirlenen kriterlere uygun olarak 100 farklı sonuç yer almıştır. Sonuçlar Çizelge 7.12'de verilmiştir.

Çizelge 7.12. GRI algoritması ile pandemi sonrası bulunan birliktelik kuralları.

Consequent	Antecedent	Support %	Confidence %
Peynirler	Ekmekler ve Zeytinler ve Sirkeler	0,11	100
Sebzeler	Cips sosları ve Mısır Gevrekleri ve Tavuk ürünleri	0,19	100
Yemek Malzemeleri	Unlu Mamüller ve Sirkeler ve Turşular	0,12	100
Yemek Malzemeleri	Baharatlar ve Çeşniler ve Et ve Tatlılar	0,10	100
Peynirler	Çay ve Sirkeler ve Turşular	0,07	100
Sebzeler	Yumurtalar ve Atıştırmalıklar ve Sirkeler	0,12	100
Yemek Malzemeleri	Et ve Kahve ve Tatlılar	0,09	100
Dondurulmuş Yiyecek	İçecekler ve Protein Barları ve Deniz ürünleri	0,11	100
Kuruyemiş	Şarküteri ve Kişisel Bakım ve Sirkeler	0,06	100
Kuruyemiş	Şarküteri ve Şekerleme ve Çikolatalar ve Sirkeler	0,06	100
Süt ürünleri	Soslar ve Mısır Gevrekleri ve Deniz ürünleri	0,10	100
Süt ürünleri	Bal ve tatlandırıcılar ve Tavuk ürünleri ve Deniz ürünleri	0,10	100
Peynirler	Kurabiye ve Kekler ve Şarküteri ve Sirkeler	0,06	100
Peynirler	Yumurtalar ve Sirkeler ve Tatlılar	0,06	100
Yemek Malzemeleri	Unlu Mamüller ve Sirkeler ve Kahve	0,08	100
Sebzeler	Bal ve tatlandırıcılar ve Cips sosları ve Tavuk ürünleri	0,12	100
Meyveler	Yumurtalar ve Et ve Sirkeler	0,12	100
Dondurulmuş Yiyecek	İçecekler ve Protein Barları ve Mısır Gevrekleri	0,10	100
Süt ürünleri	Mısır Gevrekleri ve Baharatlar ve Çeşniler ve Kağıt Havlu ürünleri	0,09	100
Dondurulmuş Yiyecek	Yumurtalar ve Mısır Gevrekleri ve Turşular	0,09	100
Yemek Malzemeleri	Yumurtalar ve Sirkeler ve Turşular	0,07	100
Süt ürünleri	Bal ve tatlandırıcılar ve Mısır Gevrekleri ve Deniz ürünleri	0,09	100
Sebzeler	Mısır Gevrekleri ve Baharatlar ve Çeşniler ve Tavuk ürünleri	0,10	100
Sebzeler	Bal ve tatlandırıcılar ve Soslar ve Deniz ürünleri	0,10	100

Çizelge 7.12. (devam ediyor).

Kuruyemiş	Atıştırmalıklar ve Şarküteri ve Sirkeler	0,05	100
Yemek Malzemeleri	Çay ve Sirkeler ve Turşular	0,07	100
Peynirler	Şarküteri ve Sirkeler ve Tatlılar	0,05	100
Peynirler	Ekmekler ve Etnik	0,05	100
Peynirler	Dondurulmuş Yiyecek ve Unlu Mamüller ve Etnik	0,05	100
Peynirler	Protein Barları ve Ekmekler ve Çay	0,05	100
Yemek Malzemeleri	Cips sosları ve Sirkeler ve Tatlılar	0,06	100
Yemek Malzemeleri	Cips sosları ve Sirkeler ve Turşular	0,06	100
Dondurulmuş Yiyecek	Protein Barları ve Peynirler ve Et	0,08	100
Sebzeler	Bal ve tatlandırıcılar ve Soslar ve Tavuk ürünleri	0,09	100
Meyveler	Bal ve tatlandırıcılar ve Soslar ve Tavuk ürünleri	0,09	100
Mısır Gevrekleri	Protein Barları ve Peynirler ve Vitamin	0,03	100
Deniz ürünleri	Protein Barları ve Çay ve Yağlar	0,03	100
Dondurulmuş Yiyecek	Unlu Mamüller ve Mısır Gevrekleri ve Turşular	0,08	100
Dondurulmuş Yiyecek	Ekmekler ve Sirkeler ve Tatlılar	0,08	100
Dondurulmuş Yiyecek	Peynirler ve Mısır Gevrekleri ve Vitamin	0,08	100
Yemek Malzemeleri	Unlu Mamüller ve Kuruyemiş ve Vitamin	0,06	100
Peynirler	Soslar ve Etnik	0,05	100
Peynirler	Şarküteri ve Zeytinler ve Sirkeler	0,05	100
Peynirler	Meyveler ve Ekmekler ve Etnik	0,05	100
Sebzeler	Mısır Gevrekleri ve Tavuk ürünleri ve Kahve	0,09	100
Sebzeler	Mısır Gevrekleri ve Baharatlar ve Çeşniler ve Yağlar	0,09	100
Sebzeler	Bal ve tatlandırıcılar ve Tavuk ürünleri ve Kağıt Havlu ürünleri	0,09	100
Meyveler	Yumurtalar ve Vitamin ve Tavuk ürünleri	0,09	100
Kuruyemiş	Şarküteri, Çay ve Sirkeler	0,04	100

Çizelge 7.12. (devam ediyor).

DondurulmuşYiyecek	Bal ve Tatlandırıcılar ve Mısır Gevrekleri ve Et	0,07	100
Yemek Malzemeleri	Kağıt Havlu ürünleri ve Turşular ve Tatlılar	0,06	100
Yemek Malzemeleri	Çay ve Sirkeler ve Kahve	0,06	100
Yemek Malzemeleri	Atıştırmalıklar ve Sirkeler ve Kahve	0,06	100
Yemek Malzemeleri	Unlu Mamüller ve Şekerleme ve Çikolatalar ve Vitamin	0,06	100
Yemek Malzemeleri	İçecekler ve Unlu Mamüller ve Etnik	0,06	100
Meyveler	Sebzeler ve Vitamin ve Deniz ürünleri	0,08	100
Vitamin	Reçeller ve Tozlu İçecekler ve Yağlar	0,02	100
Süt ürünleri	Mısır Gevrekleri ve Kağıt Havlu ürünleri ve Turşular	0,06	100
Peynirler	Züccaciye ve Turşular	0,04	100
Peynirler	Yemek Malzemeleri ve Soslar ve Etnik	0,04	100
Peynirler	Atıştırmalıklar ve Züccaciye ve Yağlar	0,04	100
Peynirler	Unlu Mamüller ve Tatlılar ve Etnik	0,04	100
Peynirler	Unlu Mamüller ve Şekerleme ve Çikolatalar ve Etnik	0,04	100
Peynirler	Unlu Mamüller ve Süt ürünleri ve Etnik	0,04	100
Peynirler	Ekmekler ve Yemek Malzemeleri ve Etnik	0,04	100
Peynirler	Ekmekler ve Süt ürünleri ve Etnik	0,04	100
Peynirler	İçecekler ve Soslar ve Etnik	0,04	100
Peynirler	İçecekler ve Ekmekler ve Etnik	0,04	100
DondurulmuşYiyecek	Mısır Gevrekleri ve Temizlik ürünleri ve Kahve	0,07	100
DondurulmuşYiyecek	Mısır Gevrekleri ve Et ve Kahve	0,07	100
DondurulmuşYiyecek	Soslar ve Kahve ve Tatlılar	0,07	100
DondurulmuşYiyecek	Protein Barları ve Peynirler ve Mısır Gevrekleri	0,07	100
Kurabiye ve Kekler	Zuccaciye ve Kuruyemişve Baharatlar ve Çeşniler	0,04	100
Kurabiye ve Kekler	Bal ve tatlandırıcılar ve Şarküteri ve Kahve	0,04	100

Çizelge 7.12. (devam ediyor).

Atıştırmalıklar	Yumurtalar ve Protein Barları ve Şekerleme ve Çikolatalar	0,05	100
Sebzeler	Soslar ve Tavuk ürünleri ve Turşular	0,08	100
Meyveler	Yumurtalar ve Şarküteri ve Çay	0,08	100
Tatlılar	Reçeller ve Kuruyemiş ve Bebek ürünleri	0,03	100
Kuruyemiş	Yumurtalar ve Şarküteri ve Sirkeler	0,03	100
Yemek Malzemeleri	Süt ürünleri ve Soslar ve Bebek ürünleri	0,05	100
Yemek Malzemeleri	Kurabiye ve Kekler ve Unlu Mamüller ve Vitamin	0,05	100
Yemek Malzemeleri	Peynirler ve Vitamin ve Turşular	0,05	100
Yemek Malzemeleri	Protein Barları ve Soslar ve Et	0,05	100
Süt ürünleri	Şarküteri ve Yağlar ve Tavuk ürünleri	0,06	100
Sebzeler	Tavuk ürünleri ve Kahve ve Turşular	0,07	100
Sebzeler	Yağlar ve Tavuk ürünleri ve Kahve	0,07	100
Sebzeler	Kişisel Bakım ve Vitamin ve Tavuk ürünleri	0,07	100
Sebzeler	Bal ve tatlandırıcılar ve Kişisel Bakım ve Deniz ürünleri	0,07	100
Sebzeler	Yumurtalar ve Sirkeler ve Turşular	0,07	100
Mısır Gevrekleri	Protein Barları ve Tavuk ürünleri ve Deniz ürünleri	0,02	100
Mısır Gevrekleri	Protein Barları ve Vitamin ve Kağıt Havlu ürünleri	0,02	100
Mısır Gevrekleri	Protein Barları ve Ekmekler ve Vitamin	0,02	100
Mısır Gevrekleri	Bal ve tatlandırıcılar ve Protein Barları ve Et	0,02	100
Mısır Gevrekleri	Bal ve tatlandırıcılar ve Protein Barları ve Reçeller	0,02	100
Deniz ürünleri	Ekmekler ve Zeytinler ve Etnik	0,02	100
Deniz ürünleri	Bal ve tatlandırıcılar ve Protein Barları ve Et	0,02	100
Deniz ürünleri	Bal ve tatlandırıcılar ve Protein Barları ve Reçeller	0,02	100
Deniz ürünleri	Bal ve tatlandırıcılar ve Protein Barları ve Soslar	0,02	100
Dondurulmuş Yiyecek	Mısır Gevrekleri ve Kağıt Havlu ürünleri ve Turşular	0,06	100

7.5.4.3. Bulgular

- Ekmek, sirke ve zeytinin görülme olasılığı %11'dir. Ekmek, sirke ve zeytin satın alan müşteriler arkasından %100 olasılıkla peynir satın almıştır.
- Cips sosları, Mısır gevrekleri ve tavuk ürünleri görülme olasılığı %19'dur. Cips sosları, Mısır gevrekleri ve tavuk ürünleri satın alan müşteriler arkasından %100 olasılıkla sebze satın almıştır.
- Unlu mamul, sirke ve turşunun görülme olasılığı %12'dir. Unlu mamul, sirke ve turşu satın alan müşteriler arkasından %100 olasılıkla yemek malzemeleri satın almıştır.
- Baharat, çeşni, et ve tatlı görülme olasılığı %10'dur. Baharat, çeşni, et ve tatlı satın alan müşteriler arkasından %100 olasılıkla yemek malzemeleri satın almıştır.
- Çay, sirke ve turşu görülme olasılığı %7'dir. Çay, sirke ve turşu satın alan müşteriler arkasından %100 olasılıkla peynir satın almıştır.
- Yumurta, atıştırmalıklar ve sirke ürünleri görülme olasılığı %12'dir. Yumurta, atıştırmalıklar ve sirke ürünleri satın alan müşteriler arkasından %100 olasılıkla sebze satın almıştır.
- Et, kahve, tatlı görülme olasılığı %9'dur. Et, kahve, tatlı satın alan müşteriler arkasından %100 olasılıkla yemek malzemeleri satın almıştır.

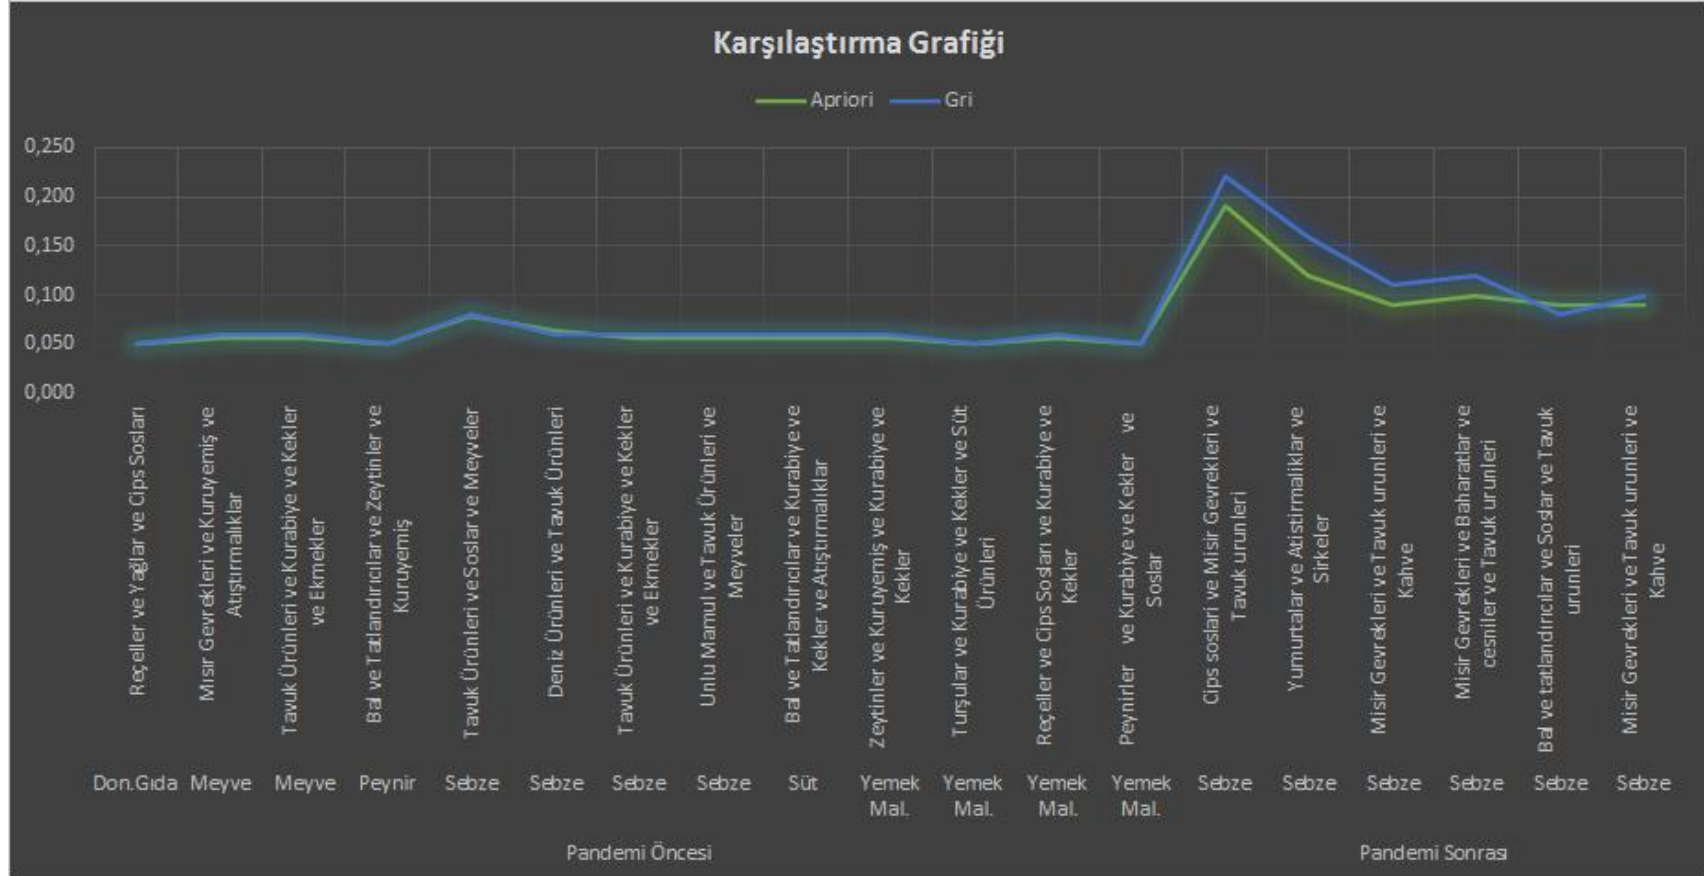
7.5.5. GRI Algoritması ve Apriori Algoritmasının Karşılaştırılması

Apriori algoritması ve GRI algoritmasının sonuçlarının karşılaştırılması, Çizelge 7.13'te verilmiştir.

Çizelge 7.13. Apriori ve GRI algoritması sonuçlarının karşılaştırılması.

	Consequent	Antecedent	Apriori	Gri
Pandemi Öncesi	Dondurulmuş Gıda	Reçeller ve Yağlar ve Cips Sosları	0,050	0,050
	Meyveler	Mısır Gevrekleri ve Kuruyemiş ve Atıştırmalıklar	0,057	0,060
	Meyveler	Tavuk Ürünleri ve Kurabiye ve Kekler ve Ekmekler	0,057	0,060
	Peynirler	Bal ve Tatlandırıcılar ve Zeytinler ve Kuruyemiş	0,050	0,050
	Sebzeler	Tavuk Ürünleri ve Soslar ve Meyveler	0,079	0,080
	Sebzeler	Deniz Ürünleri ve Tavuk Ürünleri	0,064	0,060
	Sebzeler	Tavuk Ürünleri ve Kurabiye ve Kekler ve Ekmekler	0,057	0,060
	Sebzeler	Unlu Mamul ve Tavuk Ürünleri ve Meyveler	0,057	0,060
	Süt Ürünleri	Bal ve Tatlandırıcılar ve Kurabiye ve Kekler ve Atıştırmalıklar	0,057	0,060
	Yemek Malzemeleri	Zeytinler ve Kuruyemiş ve Kurabiye ve Kekler	0,057	0,060
	Yemek Malzemeleri	Turşular ve Kurabiye ve Kekler ve Süt Ürünleri	0,050	0,050
	Yemek Malzemeleri	Reçeller ve Cips sosları ve Kurabiye ve Kekler	0,057	0,060
	Yemek Malzemeleri	Peynirler ve Kurabiye ve Kekler ve Soslar	0,050	0,050
	Pandemi Sonrası	Sebzeler	Cips sosları ve Mısır Gevrekleri ve Tavuk ürünleri	0,19
Sebzeler		Yumurtalar ve Atıştırmalıklar ve Sirkeler	0,12	0,16
Sebzeler		Mısır Gevrekleri ve Tavuk ürünleri ve Kahve	0,09	0,110
Sebzeler		Mısır Gevrekleri ve Baharatlar ve Çeşniler ve Tavuk ürünleri	0,1	0,120
Sebzeler		Bal ve Tatlandırıcılar ve Soslar ve Tavuk ürünleri	0,09	0,080
Sebzeler		Mısır Gevrekleri ve Tavuk ürünleri ve Kahve	0,09	0,100

Çıkan sonuçlara göre beklenildiği gibi Apriori algoritması ve GRI algoritması birbirine yakındır. Apriori algoritması ve GRI algoritmasının sonuçlarının karşılaştırılması, Şekil 7.6’da verilmiştir.



Şekil 7.6. Apriori algoritması ve GRI algoritmasının sonuçlarının karşılaştırılması.

GRI algoritmasının destek (support) değerleri daha yüksek olduğu için tercih edilmiştir.

Covid-19 pandemisinin perakende sektörüne etkisi ve satın alınan ürünlerin değişim yüzdesi Çizelge 7.14’te verilmiştir.

Çizelge 7.14. Pandeminin perakende sektörüne etkileri.

Sıra	Satılan Ürün Grupları	Pandemi Öncesi	Pandemi Sonrası	Değişim Yüzdesi
1	Tatlılar	62	1346	2071
2	Temizlik Ürünleri	154	1841	1095
3	Unlu Mamül	252	2613	937
4	Kâğıt Havlu Ürünleri	203	1663	719
5	Et	207	1664	704
6	Tavuk Ürünleri	245	1882	668
7	Kişisel Bakım	338	2550	654
8	Çay	178	870	389
9	Dondurulmuş Yiyecek	1699	7696	353
10	Sebzeler	2166	8724	303
11	Yumurtalar	825	3046	269
12	Meyveler	2442	8926	266
13	Süt Ürünleri	2508	7047	181
14	Protein Barları	317	309	-3
15	Züccaciye	320	155	-52

Özellikle mart ayında vaka sayılarının peak değerine ulaşmasıyla beraber insanlar evlerinde karantinaya girmiş, bu süreçte evde hamur işi yapabilmek adına unlu mamul (un, kabartma tozu, maya vb.), yumurta, süt ürünleri gibi ürünleri daha fazla tüketmişlerdir. Öte yandan virüsten korunmak için, temizlik ürünleri (dezenfektan, kolonya, ıslak mendil vb.) ayrıca dışarıya fazla çıkmak istemedikleri için çay, meyve, sebze, et, tavuk, dondurulmuş yiyecek gibi ürünleri stoklu şekilde almışlardır.

Covid-19 pandemisi züccaciye (bardak, tabak vb.) ürünlerinin satışını olumsuz etkilemiştir, müşteriler bu dönemde daha çok gıda ve temizlik sektörüne yönelmişlerdir.

BÖLÜM 8

SONUÇLAR VE ÖNERİLER

Covid-19 salgını ilk olarak Çin’de ortaya çıkmış olup, kısa bir süre içerisinde tüm dünyayı etkisi altına almıştır. Öyle ki, devletlerin izlediği politikalar Covid-19 salgını doğrultusunda yeniden şekillenmiştir. Bununla birlikte, tüketicilerin alışveriş eğilimleri de doğrudan değişkenlik göstermiştir. Pandeminin yayılımını engellemek için sokağa çıkma yasakları ilân edilip, günler süren karantina önlemleri alınmıştır. Bu önlemlerin yanı sıra, uygulamaya alınan birçok kısıtlama tedarik zincirinde çeşitli aksamalara neden olmuştur. Bu durum ise arz-talep dengesinde değişiklikler meydana getirmiştir. Örneğin; maske, eldiven, kolonya gibi kişisel bakım ürünlerindeki talep artışı piyasada yeterli ürün bulunamamasına ve buna bağlı olarak ürünlerde ciddi fiyat artışlarına neden olmuştur.

Pandemi döneminde evinde daha çok vakit geçirmeye başlayan tüketiciler gıda ürünlerini stoklamaya başlamıştır. Bu durum gıda sektöründe faaliyet gösteren işletmeleri dinamik bir döneme sokmuştur. Buradan hareketle pandeminin gıda sektörünü kazançlı hâle getirdiği söylenebilir. Bir diğer örnek ise, evde geçirilen zamanın artması ile, evde yemek pişirme trendi oluşmasıdır. Bunun sonucunda; un, maya gibi unlu mamül üretiminde kullanılan ürünlerin satışları büyük oranda artmış ve bu ürünlerin tedarikinde rekabetin de artmasına sebep olmuştur.

Bu çalışmada Amerika Birleşik Devletleri’nin Massachusetts eyaletinde bulunan ve perakendecilik sektöründe hizmet veren bir işletmenin market verileri kullanılarak, birliktelik kuralları algoritmalarından Apriori ve GRI algoritmaları yardımıyla pandemi öncesi ve pandemi sonrası dönemde tüketicilerin satın alma eğilimlerinde bir değişim olup olmadığı incelenmiştir. Ayrıca, uygulama sonunda Apriori ve GRI algoritmalarının sonuçları karşılaştırılmıştır.

Apriori algoritması ile yapılan analiz sonucunda; Covid-19 pandemisi öncesi satışlarda en yüksek destek değeri %8 oranıyla tavuk ürünleri, soslar, meyve ve sebzelerin birlikte görüldükleri tespit edilmiştir. Covid-19 pandemisi sonrası satışlarda en yüksek destek değerine sahip kural ise %54 oranıyla tavuk ürünleri, yumurta, ekme, peynir, meyve ve sebzelerin birlikte görüldüğü sonucuna ulaşılmıştır.

GRI algoritması ile yapılan analiz sonucunda; Covid-19 pandemisi öncesi satışlarda %8 oranıyla en yüksek destek değerine sahip kural olan meyve, soslar, tavuk ürünleri ve sebzelerin birlikte görüldüğü tespit edilmiştir. Covid-19 pandemisi sonrası satışlarda %19 oranıyla en yüksek destek değerine sahip kural olan cips sosları, mısır gevrekleri, tavuk ürünleri ve sebzelerin birlikte görüldüğü sonucuna ulaşılmıştır.

Apriori ve GRI algoritmalarının uygulama sonucunda aynı ya da birbirine çok yakın olarak elde edilen destek değerleri incelendiğinde; Covid-19 pandemisi öncesinde her iki algoritmaya göre de deniz ürünleri, tavuk ürünleri ve sebzeler; unlu mamüller, tavuk ürünleri, meyveler ve sebzeler; peynir, kurabiye, kek, sos ve yemeklik malzemeler birlikte görülmüştür. Covid-19 pandemisi sonrasında ise, mısır gevrekleri, baharatlar, çeşniler, tavuk ürünleri ve sebzeler; yumurta, atıştırmalıklar, sirke ve sebzeler; mısır gevrekleri, tavuk ürünleri, kahve ve sebzeler birlikte görülmüştür.

Genel olarak Covid-19 pandemisi öncesi çoğunlukla meyve, sebze, atıştırmalıklar ve deniz ürünlerinin bir arada alındığı; pandemi sonrasında ise sebze, tavuk ürünleri, unlu mamul üretim malzemeleri, peynir, et, tek kullanımlık kâğıt ve dondurulmuş yiyeceklerin birlikte çok fazla alındığı gözlemlenmiştir.

Günümüzde Covid-19 aşısı üzerindeki çalışmalar sürdürülürken, pandeminin ne zaman sona ereceği ile ilgili kesin bir bilgi bulunmamaktadır. Ancak, Covid-19 pandemisinin tüketici satın alma eğilimini doğrudan etkilediği ve tüketici satın alma davranışında pandemi öncesine göre yeni bir dönem başladığı aşikârdır. Bu nedenle gıda ürünleri satan market ve işletmeler, satın alma ve satış stratejilerini gözden geçirerek en az risk ile en yüksek kârlılığa ulaşabilecek şekilde değişen koşullara

uyum sađlamayı hedeflemelidirler. Bir sonraki alıřmada Covid-19 pandemisinin tüketicilerde satın alma eğilimi üzerindeki uzun vadeli etkileri incelenebilir.

KAYNAKLAR

1. HAN, J. ve Kamber, M., “Data Mining Concepts and Techniques İkinci Baskı”, Kitap, *Morgan Kaufmann*, San Francisco, ss. 4-5, 2006.
2. Acar, N., “Perakendecilikte Mağaza Atmosferinin Müşteri Sadakatine Etkisi” Yayınlanmamış Doktora Tezi, *Erciyes Üniversitesi Sosyal Bilimler Enstitüsü*, Kayseri, (2009).
3. Börekci, M., “Pazarlama Estetiğinde Mağaza İmajının Tüketici Algısı Üzerindeki Rolü: Kozmetik Sektöründe Bir Uygulama” Yayınlanmamış Yüksek Lisans Tezi, *Abant İzzet Baysal Üniversitesi Sosyal Bilimler Enstitüsü*, Bolu, (2008).
4. Şimşek, B., “Marka Kişiliği: Gıda Perakende Sektöründe Bir Uygulama”, Yüksek Lisans Tezi, *İstanbul Ticaret Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul (2015).
5. Alkan, A., “Dönüşürken Büyüyen Türkiye Perakende Sektörü” *Türkiye Alışveriş Merkezleri ve Perakendeciler Federasyonu*, Ocak 2016 Sayısı, s.4-5.
6. Özden, A. T. “Etnosentrik Eğilimin Tüketicilerin Satın Alma Davranışına Etkisi: Doğu Anadolu ve Karadeniz Bölgeleri Üzerine Karşılaştırmalı Analiz”, Yayınlanmamış Doktora Tezi, *Başkent Üniversitesi*, Ankara, (2007).
7. Doğrul, Ü. “Elektronik Alışveriş Davranışında Faydacı ve Hedonik Güdülerin Etkisi” *Sosyal ve Beşeri Bilimler Dergisi*, 4(1), 321-331, (2012).
8. İnternet: Redman, R., “Among U.S. Grocery Shoppers, 85% Say Covid-19 Hitting Them in Pocketbook”, <https://www.supermarketnews.com/consumer-trends/among-us-grocery-shoppers-85-say-covid-19-hitting-them-pocketbook>, (2020). 03.01.2021 tarihinde erişilmiştir.
9. Chenarides, L., Grebitus, C., Lusk, J., and Printezis, I., “Food Consumption Behavior During the COVID-19 Pandemic”, *International Journal of Agribusiness*, 37, 44-81, (2021).
10. Babaoğul, M., Şener, A. ve Buğday, B., “Tüketici Profili, Eğilimleri ve Davranışlarının Analizi”, T.C Gümrük ve Ticaret Bakanlığı Tüketicinin Korunması ve Piyasa Gözetimi Genel Müdürlüğü, 2016.
11. Peterson, R. A., “Response Construction in Consumer Behavior Research”, *Journal of Business Research*, 58, ss. 348-353, (2005).

12. Fernandes N., “Economic Effects of Coronavirus Outbreak (Covid-19) on the World Economy”, *Ssrn, Preliminary and Subject to Revisions as New Data is Released*, Ver.2, (March, 2020).
13. İnternet: Widjaja, J., and Chipeta, C., “Survey: Consumer Behaviour During Covid 19 Pandemic”, <https://conjointly.com/blog/covid-consumer-impact-survey/>, Erişim Tarihi: 01.09.2020.172 5th International Scientific Research Congress (IBAD - 2020) Bildiriler September 1-2, 2020 ibadcongresses, (2020).
14. Simon, W., L., “The Economic Effects of a Pandemic”, *CEPR Press*, London, (2020).
15. Ersöz, F., “Veri Madenciliği Teknikleri ve Uygulamaları”, *Seçkin Kitabevi*, Ankara, (2019).
16. İnternet: “A Gentle Introduction on Market Basket Analysis - Association Rules” <https://towardsdatascience.com/a-gentle-introduction-on-market-basket-analysis-association-rules->, (2017). 03.12.2020 tarihinde erişilmiştir.
17. İnternet: World Health Organization, “WHO Coronavirus Disease (COVID-19) Dashboard”, <https://covid19.who.int/> (2021). 06.01.2021 tarihinde erişilmiştir.
18. Mitchel, T., O'Donnell, G., Taves, R., Weselake-Goerge, Z., ve Xu, A. “Consumer Expenditures During Covid-19: An Exploratory Analysis of The Effects of Changing Consumption Patterns on Consumer Price Indexes”, *Statistics Canada*, (July, 2020).
19. İnternet: Statista, “Food”, <https://www.statista.com/outlook/40040300/109/food/united-states>, (2021). 08.02.2021 tarihinde erişilmiştir.
20. Knotek II, E.S., Schoenle, R., Dietrich, A., Kuester, K., Müller, G., Myrseth, K.O.R., ve Weber, M., (2020), “Consumers and COVID-19: A Real-Time Survey”, *Economic Commentary*, (2020-08), s.1-6.
21. Stanciu, S., Radu, R.I., Sapira, V., ve Dumitrache, B., “Consumer Behavior in Crisis Situations- Research on The Effects of COVID-19 in Romania”, *Annals of Dunarea de Jos University of Galati*, s.5-13, (2020).
22. İnternet: Widjaja, J., and Chipeta, C., “Survey: Consumer Behaviour During Covid-19 Pandemic”, <https://conjointly.com/blog/covid-consumer-impact-survey/>, (2020). 12.01.2021 tarihinde erişilmiştir.
23. İnternet: Criteo, “5 Ways the Coronavirus is Affecting Consumer Behavior”, <https://www.criteo.com/insights/coronavirusconsumer-behavior/>, (2020).
24. İnternet: Statista, “Bozulabilir Yiyecek Tüketim Raporu” <https://www.Statista.com/chart/21109/sales-growth-of-non-perishablefood-items-in-the-us/>, (2020).
25. İnternet: İpsos, “Hane Tüketim Paneli”, <https://www.ipsos.com/tr-tr>, (2020).

26. İnternet: Dinozo, C., “Survey: How is COVID-19 Changing Consumer & eCommerce Trends?”, <https://www.yotpo.com/blog/survey-how-is-covid-19-changing-consumer-ecommerce-trends/> (2020). 22.12.2020 tarihinde erişilmiştir.
27. Alpaydın, E., “Zeki Veri Madenciliği: Ham Veriden Altın Bilgiye Ulaşma Yöntemleri”, *Bilisim 2000 Eğitim Semineri*, 1-10, (2000).
28. Brown, J. S., ve Duguid, P., “Enformasyonun Sosyal Yaşamı”, (Çev. İbrahim Bingöl), *Türk Henkel Dergisi Yayınları*, İstanbul (2001).
29. Davenport, T. “Big Data @ Work, (M. Çavdar, Çev.)”, *İstanbul: Türk Hava Yolları Yayınları* (2014).
30. Kaya, Y. ve Tekin, R., “Veritabanı ve Uygulamaları”, *Papatya Yayıncılık Eğitim*, İstanbul, (2007).
31. Döşlü, A., “Veri Madenciliğinde Market Sepet Analizi ve Birliktelik Kurallarının Belirlenmesi” Yüksek Lisans Tezi, *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, (2008).
32. Rainer K., Prince, B., Watson, H., “Management Information Systems, 4th Edition” *Data and Knowledge Management*, (2017).
33. Kimball, R. and M. Ross. “The Data Warehouse Toolkit: The Complete Guide to Dimensional Modeling (Second Edition)”, New York, *John Wiley & Sons*, (2000).
34. Cios Krzysztof J., Pedrycz, Witold, Swiniarski, Roman W. and Kurgan, Lukasz A. “Data Mining Knowledge Discovery Approach”, *Eespringer Science Business Media*, USA, (2007).
35. Akpınar, H., (2000), “Veri Tabanlarında Bilgi Keşfi Ve Veri Madenciliği”, *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, vol. 29, pp. 1-22, (2000).
36. Akgöbek, Ö. ve Çakır, F., “Veri Madenciliğinde Bir Uzman Sistem Tasarımı”, *Akademik Bilişim*, 9, 801-806, (2009).
37. Timor, M. ve Şimşek, U. T. “Veri Madenciliğinde Sepet Analizi ile Tüketici Davranışı Modellemesi”, *Yönetim*, 19 (59), 3-10, (2008).
38. Dener, M., Dörterler, M. ve Orman, A., “Açık Kaynak Kodlu Veri Madenciliği Programları: WEKA’da Örnek Uygulama Akademik Bilişim’09”, *XI. Akademik Bilişim Konferansı Bildirileri*, Harran Üniversitesi, Şanlıurfa, ss.787-796, (2009).

39. Kaymaz, M., “Veri Madenciliği Yöntemi İle Risklerin Yönetilmesi Ve Sigorta Sektörü Üzerine Bir Uygulama “, Yüksek Lisans Tezi, *Marmara Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, (2019).
40. Silahtaroğlu, G., “Kavram ve Algoritmalarıyla Temel Veri Madenciliği”, *Papatya Yayıncılık Eğitim*, İstanbul, (2008).
41. Bergeron, B., “Essentials of CRM: A Guide to Customer Relations Management”, *John Wiley&Sons*, USA, s. 80, (2002).
42. Demir, F., Kırdar, Y., “Müşteri İlişkileri Yönetimi: CRM”, Review of Social, Economic & Business Studies, C.VII, No:8, s.297
43. Michael J. Shaw, v.d., “Knowledge Management and Data Mining for Marketing,” *Decision Support Systems*, No:31, s. 133.
44. Sang C. Park, Selwyn Piramuthu, Michael J. Shaw, “Dynamic Rule Refinement in Knowledge Based Data Mining Systems”, *Decision Support Systems*, No:31, s.206, (2001).
45. Akçay, A., “Bilgi ve Belge Yönetiminde Veri Madenciliği”, Yüksek Lisans Tezi, *İstanbul Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, (2014).
46. Nan-Chen Hsieh, “An Integrated Data Mining and Behavioral Scoring Model For Analyzing Bank Customers”, *Expert Systems with Applications*, C.XXVII, No:4, s.3.
47. Larose, D., “Discovering Knowledge in Data: An Introduction to Data Mining”, *John Wiley & Sons Inc.*, s. 42, (2005).
48. Larose, D. T. “Discovering Knowledge in Data: An Introduction to Data Mining”, *John Wiley & Sons*, New Jersey, Published Simultaneously in Canada, (2014).
49. Denizli, Z., “Veri Madenciliği Modelleri ve Örnek bir Uygulama”, Yüksek Lisans Tezi, *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü*, İzmir, (2019).
50. Dolgun M.Ö., “Büyük Alışveriş Merkezleri için Veri Madenciliği Uygulamaları”, Yüksek Lisans Tezi, *Hacettepe Üniversitesi İstatistik Anabilim Dalı*, Ankara, (2006).
51. Han, Jiawei-Kamber, Micheline, “Data Mining: Concepts and Techniques”, *Morgan Kaufmann Publishers, 1st Ed.*, San Francisco, USA, 2000, s.287
52. Oskaybaş, N. M., “Kayseri’de Faaliyet Gösteren Bir İşletmede Satış Verileri Üzerine Veri Madenciliği Uygulaması”, Yüksek Lisans Tezi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü*, Kayseri, (2017).

53. Sun J. and Li H., “Data Mining Method for Listed Companies, Financial Distress Prediction”, *Knowledge-Based Systems*, C. 21, S. 1, s. 1–5, (2008).
54. Berry, M., “Data Mining Techniques: For Marketing, Sales, and Customer Relationship Management”, *John Wiley and Sons Incorporated*, USA, (2004).
55. Aitkenhead M. J., “A Co-Evolving Decision Tree Classification”, *Expert Systems with Applications*, C. 34, S. 1, s. 18–25, (2008).
56. Quinlan, J. R., “Induction of Decision Trees”, *Machine Learning*, vol (1), pp.81-106, (1986).
57. Quinlan, J. R., “Simplifying Decision Trees”, *International Journal of Machine Studies*, number27, pp. 221-234, (1987).
58. Quinlan, J. R. “C45: Programs for Machine Learning”, Morgan Kaufmann, San Mateo, CA, (1993).
59. Gülpınar, V., “Avrupa Birliği Ülkeleri ile Türkiye’nin Ekonomik Göstergelerinin Karar Ağacı Yöntemi ile Karşılaştırılması,” Yayımlanmamış Yüksek Lisans Tezi, *Marmara Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, (2008).
60. Yücesoy, Ü., “Firmaların Finansal Kararlarında Uyguladıkları Finansal Karar Yöntemleri Ve Karar Ağacı Uygulaması”, Yayımlanmamış Yüksek Lisans Tezi, *Haliç Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, (2014).
61. Rud, O. P., *Data Mining Cookbook Modeling Data For Marketing, Risk And Customer Relationship Management*, New York, John Wiley, 2001, s. 16
62. Kurup, P. U., Dudani, N. K., “Neural Networks for Profiling Stress History of Clays From Pcpt Data”, *Journal Of Geotechnical & Geoenvironmental Engineering*, Vol. 128, Issue 7, p. 569, 11p, (2002).
63. Çelik, M., “Veri Madenciliğinde Kullanılan Sınıflandırma Yöntemleri Ve Bir Uygulama” Yüksek Lisans Tezi, *İstanbul Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, (2009).
64. Düzgün, O., “Veri Madenciliği Yöntemleri ve İŞKUR İçin Uygulamaya Yönelik Model Önerisi”, Uzmanlık Tezi, *Çalışma ve Sosyal Güvenlik Bakanlığı Türkiye İş Kurumu Genel Müdürlüğü*, Ankara, (2017).
65. Atan, S., “KNN, Naive Bayes ve Karar Ağacı Makine Öğrenme Algoritmaları, Bu Algoritmaların Sosyal Bilimlerde Kullanım İmkânları”, *SocArXiv*, 3 May 2020.
66. Yakupoğlu, Y., “Eğitimsel Veri Madenciliği ve Bir Uygulaması”, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Endüstri Mühendisliği Anabilim Dalı*, İstanbul, (2018).

67. Bilekdemir, G., “Veri Madenciliği Tekniklerini Kullanarak Üretim Süresi Tahmini Ve Bir Uygulama”, Yüksek Lisans Tezi, **Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü**, İzmir, (2010).
68. Yıldırım, B., “Modern Perakendecilik Sektöründe Veri Madenciliği Tekniklerinin Uygulanması”, Yüksek Lisans Tezi, **İstanbul Üniversitesi-Cerrahpaşa Lisansüstü Eğitim Enstitüsü**, İstanbul, (2019).
69. Özdemir, A., & Yalçın, F. A., & Çam, H. (2009), “Veri Tabanında Bilgi Keşfi Süreci: Gümüşhane Devlet Hastanesi Uygulaması”, **Sosyal Ekonomik Araştırmalar Dergisi**, 1(20), 347-366.
70. Arslan, H., “Sakarya Üniversitesi Web Sitesi Erişim Kayıtlarının Web Madenciliği İle Analizi” Yüksek Lisans Tezi, **Sakarya Üniversitesi Fen Bilimleri Enstitüsü**, Sakarya, (2008).
71. Ramageri, B. M., “Data Mining Techniques And Applications”, **Indian Journal of Computer Science and Engineering**, Volume 1, December, No. 4, Pages 301-305, (2010).
72. Simar, W. H., Leopold, “Applied Multivariate Statistical Analysis”, **Springer, Second Edition**, Berlin Almanya, 2007.
73. Bramer, M., “Principles of Data Mining”, **Springer**, London, 11-20, (2007).
74. İnternet: Sütton, N., “Behind The ‘Beer And Diapers’ Data Mining Legend”, <https://www.itbusiness.ca/news/behind-the-beer-and-diapers-data-mining-legend/136>, (1992). 18.01.2021 tarihinde erişilmiştir.
75. Agrawal, R., Imielinski, T., And Swami, A., "Database Mining: A Performance Perspective", IEEE Transactions on Knowledge and Data Engineering, Special Issue On Learning And Discovery In Knowledge-Based Databases, (1993).
76. Yurtsever, U., “Veri Madenciliği Ve Uygulaması”, Yüksek Lisans Tezi, **Sakarya Üniversitesi Sosyal Bilimler Enstitüsü**, Sakarya (2002).
77. M. Özçalıcı, "Veri Madenciliğinde Birliktelik Kuralları ve İkinci El Otomobil Piyasası Üzerine Bir Uygulama," **Sosyal Bilimler Arastirmalari Dergisi**, Vol. 7, (2017).
78. Khurana, K. And Sharma, S., “A Comparative Analysis of Association Rules Mining Algorithms”, **International Journal Of Scientific And Research Publications**, Volume 3, Issue 5, May 2013.
79. Agrawal, R. ve Srikant, R. “Fast Algorithms for Mining Association Rules”, **In Proc. 20th Int. Conf. Very Large Data Bases**, VLDB, Vol. 1215, pp. 487-499, 1994.

80. Han, J., Pei, J. ve Kamber, M. “Data Mining: Concepts and Techniques 3th Edition”, *Elsevier*, USA, 2011.
81. Kumbhare, T. and Chobe, S., “An Overview of Association Rule Mining Algorithms”, *International Journal of Computer Science and Information Technologies*, Vol. 5 (1), 927-930, (2014).
82. Eker, M. E., “Veri Madenciliğinde Apriori Algoritmasının Sınav Verileri Üzerinde Uygulanması”, Yüksek Lisans Tezi, *Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü*, Samsun, (2016).
83. Gündüz, S., “Veri Madenciliğinde Kullanılan Birliktelik Analizi ve Market Sepet Analizi: Bir Uygulama”, Yüksek Lisans Tezi, *On Dokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü*, Samsun, (2017).
84. Smyth, P. and Goodman, RM., “An Information Theoretic Approach to Rule Induction From Databases”, *IEEE Transactions on Knowledge and Data Engineering*, pp. 301 – 316, (1992).
85. Tokyürek, E. “Birliktelik Kural Çıkarım Algoritmaları Kullanılarak Market Sepet Analizi”, Yüksek Lisans Tezi, *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü*, Bilecik, (2019).
86. Soylu, N., “Market-Sepet Analizi Yöntemiyle Promosyonların Belirlenmesi”, Yüksek Lisans Tezi, *Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, (2019).
87. Deveci, K. İ., ve Baysal, T. G., “Perakendecilik Sektöründe Müşteri Sepet Verisi Kullanarak Fayda-Sıklık Analizi” *19. Uluslararası Ekonometri, Yöneylem Araştırması ve İstatistik Sempozyumu 2018*, Antalya, (2018).
88. Gurudath, S. “Market Basket Analysis & Recommendation System Using Association Rules” Master of Science in Big Data Management and Analytics, *Griffith College*, Dublin, (2020).
89. Kamakura, Wagner A., Sequential Market Basket Analysis (May 22, 2012).
90. Annie, L. ve Kumar, A. “Market Basket Analysis for A Supermarket Based on Frequent Itemset Mining”, *International Journal of Computer Science Issues*, Vol. 9, Issue 5, No 3, September 2012.
91. Hilage, T. A., & KulKarni, R. V., “Application of Data Mining Techniques to A Selected Business Organization with Special Reference to Buying Behavior”, *International Journal of Database Management Systems*, 3 (4), 169-181, (2011).
92. Attal vd., “Redesigning A Retail Store Based on Association Rule Mining”, *Proceedings of the International Conference on Industrial Engineering and Operations Management*, July26-2, (2018).

93. Nandy, A. “Association Rule Mining with Eclat on A Malaysian Retail Store”, *International Journal of Research in Science and Technology*, Vol. No. 8, Issue No. I, Jan-Mar (2018).
94. Prasad, P. “Using Association Rule Mining For Extracting Product Sales Patterns in Retail Store Transactions”, *International Journal on Computer Science and Engineering*, Vol. 3 No. 5, May (2011).
95. Gülce, A.,C., “Veri Madenciliği Apriori Algoritması ve Apriori Algoritmasının Farklı Veri Kümelerinde Uygulanması”, Yüksek Lisans Tezi, *Trakya Üniversitesi* Tekirdağ, (2010).
96. Gülen, Ö., Ç., Özdemir, S., “Veri Madenciliği Teknikleri ile Üstün Yetenekli Öğrencilerin İlgi Alanlarının Analizi”, *Üstün Yetenekli Eğitimli Araştırma Dergisi*, (2013).
97. Gedleç, Ş., “Çok Boyutlu Birliktelik Kuralları Analizi ve İşletme Uygulaması”, Yüksek Lisans Tezi, *Marmara Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, (2019).
98. Sağın, A., N., “Veri Madenciliği Algoritmaları ile Birliktelik Kurallarının Belirlenmesi: Perakende Sektöründe Bir Uygulama”, Yüksek Lisans Tezi, *İstanbul Ticaret Üniversitesi*, (2018).
99. Poel, V., D., and Schamphelaere J., “Direct and Indirect Effects of Retail Promotions on Sales and Profits in the Do-It-Yourself Market”, *Expert Systems with Applications*,1(27),53–62, (2004).
100. Gulluoglu, S. S. “Segmenting Customers with Data Mining Techniques”, *Digital Information, Networking, and Wireless Communications (DINWC)*, 154-159, (2015).
101. Köse, T., M., Koyuncuoğlu Ö. and Tekin, E., “The Analysis of Product Categories and Sales Relationships Among Valuable Customers Through Data Mining and Its Application to A National Retailer Through Association Rules and Cluster Analysis”, *International Interdisciplinary Business-Economics Advancement Conference*, (2015).
102. Ertugrul, I., Oztas, T., Oztas, G. Z., & Ozcil, A. “Shelf Layout With Integrating Data Mining and Multidimensional Scaling”, *European Scientific Journal*, ESJ, 12(10), (2016).

ÖZGEÇMİŞ

Ezgi ALANLAR 1992 yılında Kocaeli’de doğdu; ilk, orta ve lise öğrenimini Sakarya’da tamamladı. Sakarya Figen Sakallıođlu Anadolu Lisesi’nden mezun oldu. 2011 yılında Karabük Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliđi Bölümü’nde öğrenime başlayıp 2015 yılında mezun oldu. Bu süreçte bir dönem Endüstri Mühendisliđi Kulübü başkanlık görevini yürüttü. 2015 yılında, Ak Gıda Süt ve Süt Ürünleri A.Ş.’de Ambalaj Satın Alma Uzman Yardımcısı olarak göreve başladı. Burada üç yıl çalıştıktan sonra, 2018 yılında Amerika Birleşik Devletleri’nin Boston şehrine taşındı. 2019 yılında Harvard Üniversitesi’nden burslu olarak ders alıp, başarı ile tamamladı. Eş zamanlı olarak, Boston’da bulunan bir emlak şirketinde muhasebe departmanında çalıştı. 2020 yılı itibariyle etnik gıda ürünlerinin satın almasından sorumlu olarak bir işletmede çalışmaya başlamış olup, halen bu görevi sürdürmektedir.

ADRES BİLGİLERİ

Adres : 17 Winter St, Watertown Massachusetts, USA

E-posta : ezgi.alanlar@gmail.com