



Araştırma Makalesi / Research Article

MÜŞTERİ PROFİLİ VE ALIŞVERİŞ HAREKETLERİNİ BELİRLEMEDE RFM ANALİZİ VE BİRLİKTELİK KURALLARI ANALİZİ: PERAKENDE SEKTÖRÜNDE BİR UYGULAMA*

RFM ANALYSIS AND ASSOCIATION RULES ANALYSIS IN DETERMINING
CUSTOMER PROFILE AND SHOPPING MOVEMENTS:
AN APPLICATION IN RETAIL INDUSTRY

Gülfem OĞUR¹

Oğuz BORAT²

<https://doi.org/10.55071/ticaretfbid.1327068>

Sorumlu Yazar / Corresponding Author
gulfemogur@gmail.com

Geliş Tarihi / Received
13.07.2023

Kabul Tarihi / Accepted
31.08.2023

Öz

Günümüzde gelişen teknolojiyle birlikte hızlı değişen pazarlama dünyası artık ürün bazlı alınan stratejilerden uzaklaşarak, müşteri faktörünün önemini anlamış ve müşteriye odak noktasına koyarak çalışmaları bu yönde yapmıştır. Bu çalışmada perakende sektöründe, müşterilerin alışverişteki davranışları analiz edilerek müşteri profilleri çıkarılıp her bir müşteri profiline uygun kampanya stratejilerinin geliştirilmesi amaçlanmıştır. Yapılan çalışma iki aşamadan oluşmaktadır. Birinci aşamada, müşterilerin satın alma alışkanlıkları RFM analizi ile belirlenmiştir. RFM analizi aracılığıyla müşterinin yakın zamanda satın alma işlemi, işlem sıklığı ve satın alma büyüklüğüne göre segmentlere ayrılmıştır, sonrasında ise her segmente uygun olacak kampanya stratejileri önerilmiştir. İkinci aşamada ise veri madenciliğinde kullanılan birliktelik kuralları analizinden biri olan Apriori Algoritması kullanılarak müşterilerin satın aldıkları ürünler arasındaki bağlantıları analiz edilmiştir. Böylelikle müşterilerin hangi ürünleri birlikte satın aldıkları belirlenip kârı arttırmaya yönelik yapılabilecek stratejilere yön verilmeye çalışılmıştır. Çalışmanın sonuçlarına göre 10 farklı müşteri kümesi oluşturulmuştur. Harcama tutarları en yüksek olup, şirket açısından en karlı müşteri profiline “Champions” olduğu, en az kârlı ve yakın zamanda neredeyse hiç alışveriş yapmamış kayıp müşteri olarak adlandırığımız müşteri profillerinin ise “Hibernating” müşteri profiline olduğu belirlenmiştir.

Anahtar Kelimeler: Apriori Algoritması, pazar-sepet analizi, perakende sektörü, RFM analizi, veri madenciliği.

Abstract

With today's technology, the world of fast marketing has now moved away from product-based combined strategies, understood the change in the customer factor, and the efforts to change the customer from the focal point to the point have been carried out in this direction. In this retail sales sector, it is possible to analyze the growth in shopping in the region, to create customer profiles and to present offers suitable for each customer profile. The study consists of two stages. In the first step, the product of growth was determined by RFM analysis. Throughout the RFM analysis, the recent purchase has been segmented according to transaction costs and purchase volume, then a campaign scheme has been proposed to suit each segment. In the second stage, the links between the purchased products were analyzed by the Apriori Algorithm, which is one of the association rules analysis used in data mining. In this way, sustainable strategies for which products can be purchased together and profited begin to be guided. According to the demonstration of the study, 10 different customer settings are offered. The customer profiles that have the highest expenditure amounts and the profitable customer profile for the company are “Champions”, and the customer profiles that we call the lost customers who are the least profitable and have hardly made any purchases recently are determined by the “Hibernation” customer profiles.

Keywords: Apriori algorithm, data mining, market-basket analysis, retail industry, RFM analysis.

*Bu yayın Gülfem OĞUR isimli öğrencinin İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Tezli Yüksek Lisans Programındaki Yüksek Lisans tezinden üretilmiştir.

¹İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, İstanbul, Türkiye.
gulfem.ogur@istanbulticaret.edu.tr, Orcid.org/0000-0002-9444-8943.

²İstanbul Ticaret Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, İstanbul, Türkiye.
oborat@ticaret.edu.tr, Orcid.org/0000-0002-2242-6024.

1. GİRİŞ

Günümüzde teknolojinin gelişmesiyle birlikte hızlı değişen ve rekabetin fazla olduğu sektörlerde; çok sayıda ve çeşitli profillerde müşterisi olan işletmeler için sahip olunan müşterileri memnun etmek ve elde tutmak, en az yeni müşteriyi elde tutmak kadar önemli bir konudur (Berger & Nasr, 1998). Bu sebeple çoğu işletme, müşteri ilişkilerini geliştirerek bu rekabetçi ortamda ayakta kalabilmek için müşteri ilişkileri yönetimi (MİY) şeklini benimsemiştir (Kumar & Reinartz, 2012). Bu stratejik yaklaşımın odağında ise müşteri segmentasyonu yer almaktadır (Blattbergs & Malthouse, 2009).

Segmentasyon, şirketlerin müşteri tercihleri ve ihtiyaçları hakkında daha fazla bilgi edinmesine yardımcı olur. Böylece şirketler, müşteri memnuniyetini ve şirket gelirlerini artırmak amacıyla hedeflenen segmentler için farklı stratejiler geliştirebilir. Bu bakımdan müşteri segmentasyonu, şirketlerin müşterileri anlamalarını ve farklı stratejiler oluşturmalarını sağlayan bir pazarlama aracı olarak kullanılmaktadır (Silva ve ark., 2019).

Hedef müşteri seçimi, müşteri odaklı pazarlamanın en önemli konularından biridir. Günümüzde, sadık, karlı ve uzun vadeli müşterilerin belirlenmesi, müşteri odaklı sektörler için en önemli faktörlerin başında gelmektedir. Bu açıdan değerli müşterilerin belirlenmesinde en etkili ve en kolay model RFM (Recency, Frequency, Monetary) analizidir (Tsao ve ark., 2019). RFM analizi, kullanımı kolay ve yöneticiler tarafından anlaşılması kolay olduğu için yaygın olarak kullanılan bir yöntemdir. RFM analiz yönteminde müşterinin önceki alışveriş davranışlarının yanı sıra, yapmış olduğu alışveriş sayısına ve bu alışverişlerin harcama tutarlarına da bakılarak gelecekteki satın alma davranışları belirlenmektedir.

Bu çalışma, Türkiye’de gıda perakendeciliği sektöründe varlığını gösteren bir firmanın müşteri alışveriş kayıtları kullanılarak, veri madenciliği yöntemleri ile analiz çalışması yapılmıştır. Çalışma iki aşamadan oluşmaktadır, birinci aşamada müşterilerin en son ne zaman alışveriş yaptıkları ne sıklıkla ürün satın aldıkları ve sepet tutarları verileri baz alınarak alışverişte sergiledikleri davranışlara göre müşteri profilleri RFM analizi ile belirlenmiştir. RFM analizi ile sadık müşteri portföyünü oluşturarak müşterinin sadakatini arttıracak kampanya ve stratejiler geliştirmek amaçlanmıştır. İkinci aşamada ise birliktelik kuralları analizinden Apriori Algoritması kullanılıp müşterilerin satın aldıkları ürünler arasındaki ilişkiler belirlenmiştir. Belirlenen ilişki kuralları üzerinden satış stratejileri geliştirilip şirketin karının artırılması amaçlanmıştır.

2. LİTERATÜR ARAŞTIRMASI

Çalışmanın bu bölümünde literatürdeki RFM Analizi ve Birliktelik analizi ile ilgili yapılan çalışmalara yer verilmiştir.

Agrawal ve ark., (1993) çalışmalarında; büyük bir perakende şirketinden elde edilen satış verileri arasındaki ilişkileri belirlemek için RFM analizi kullanılmıştır. RFM analizi aracılığıyla çeşitli stratejiler geliştirilip şirketin karının artırılması amaçlanmıştır.

Bult & Wansbeek, (1995) çalışmalarında; hedeflenen karı en üst seviyeye çıkartmak için hangi müşteri profillerinin promosyon ve kampanya e-posta alması gerektiğini belirlemeye çalışmışlardır. Bu kararı vermek için müşteri değerlendirme ölçütü olarak da bilinen RFM analizi kullanmışlardır. Yapılan RFM analizi ile müşterilere verilecek tekliflere yanıt verme olasılığı yüksek olan kümeler belirlenmiştir.

Akpınar, (2000) çalışmasında; veri madenciliği kümeleme tekniklerinden biri olan “Ayrırcı Hiyerarşik Kümeleme” tekniği ile Uşak Üniversitesi Merkez Kütüphanesine kayıtlı olan öğrenci bilgilerini inceleyerek öğrencilerin kitap alma alışkanlıkları üzerine çeşitli istatistiksel bilgiler elde etmiştir. Ayrırcı hiyerarşik kümeleme analizi ile veriler 11 adet kümeye ayırmıştır. Ayrılan kümeler kendi içinde homojen, farklı kümeler arasında ise heterojen yapıdadır. Oluşturulan kümeler veri madenciliğinin görselleştirme tekniği kullanılarak çeşitli tablo ve grafikler oluşturulmuştur. Oluşturulan tablo ve grafiklerden çıkarımlar yapılarak öğrencilerin kütüphaneden kitap alma davranışları incelenmiştir.

Salvatore ve ark., (2004) çalışmalarında; veri madenciliği yöntemlerinden biri olan FP- Growth algoritmasını kullanarak minimum destekle oluşan öge kümeleri belirlemek amaçlanmıştır. Uygulanan algoritmayı daha sezgisel hale getirmek için Pazar sepet analizi kullanmışlardır. Pazar sepet analizi ile müşteriler tarafından satın alınan ürünler arasında sık görülen ilişkiler bulmuşlardır.

Gao, (2004) çalışmasında; Kümeleme algoritmasını kullanarak, veri yığınlarını anlaşılabilir formata çevirmeyi amaçlamıştır. Kullanılan algoritmanın performansını değerlendirmek için iki popüler kümeleme algoritması kullanılıp çıkan sonuçları yorumlamıştır.

Özçakır ve Çamurcu, (2007) çalışmalarında; birliktelik analizini kullanılarak bir firmanın pastane satış verileri üzerinden bir yazılım geliştirdiler. Tasarlanan yazılımda apriori algoritması kullanılarak, birlikte satın alınan ürünler arasındaki ilişkileri tespit etmişlerdir.

Chang ve Lai, (2009) çalışmalarında; Taipei şehrine gelen müşterilerin memnuniyetini sağlayıp turist sayısını arttırmak için turistlerin seyahatlerindeki davranışlarını incelemişlerdir. Analiz sonucunda pazarlama stratejileri tasarlamışlardır.

Timor ve ark., (2011) çalışmalarında; hazır giyim perakende sektöründe faaliyet gösteren bir firmanın, müşteri alışveriş kayıtları ele alınmışlardır. Yapılan analizin birinci aşamasında “Birliktelik Kuralları Analizi” kullanılarak müşterilerin alışverişlerinde birlikte aldıkları ürünler arasındaki ilişki belirlenmeye çalışılmışlar, daha sonra “Kümeleme Analizi” ile müşteriler, demografik niteliklerine göre gruplandırmışlar.

Erpolat, (2012) çalışmasında; veri madenciliği yöntemlerinden Apriori algoritmasını kullanmıştır. Otomotiv sektörüne ait olan verileri ele alıp Apriori algoritması aracılığıyla birlikte satın alınan ürünleri tespit edip, çeşitli kampanya çalışmaları önerilmiştir.

Sadiqmal, (2015) çalışmasında; veri madenciliğinde birliktelik kuralı algoritmalarından olan Apriori algoritmasını tıpla ilgili verilere uygulayıp, modern tıp bilgilerinin saklandığı veri tabanından faydalı çıkarımlar yaparak doktorlara yardımcı olacak karar destek sistemleri geliştirmiştir.

Zabkowski, (2016) çalışmasında; Geç ödemelerin RFM’sine karşılık gelen telekomünikasyon verilerini kullanarak müşteri ödeme haczini tahmin etmek için yenilik, sıklık ve parasal değer yaklaşımının uygulamasını sunmaktadır.

Ateş ve Karabatak (2016) çalışmalarında; veri madenciliği yöntemlerinden birliktelik kuralını incelemişlerdir. Birliktelik kuralında en önemli değer olan destek değerinin seçilme sorununu ortadan kaldırmak için çoklu destek değeri kullanılan yeni bir yaklaşım önermektedirler.

Sözen ve ark., (2017) çalışmalarında; Apriori algoritmasını kullanarak mobilya seçiminde önemli bir faktör olan estetik, dayanıklılık, işlevsellik ve maliyet analizleri yapmışlardır. Buna istinaden farklı müşterilerin mobilya tercihlerinde hangi kriterleri önemsendiği belirlemiştir.

Lai ve ark., (2018) çalışmalarında; döviz piyasalarındaki para birimleri arasındaki ilişkiler ele alınarak 2011 ile 2016 yıllarına ait dönemlerde Tayvan yatırımcılarının döviz hesaplarını değerlendirmek amaçlanmıştır. Tayvan para birimi ile 15 ülkenin döviz kuru verileri kullanılarak Birlikte Kuralları Analizi ve Apriori algoritması uygulanmıştır.

Yüksel ve Zontul, (2019) çalışmalarında; FP-Growth algoritması kullanarak sepet analizi tekniğini uygulamışlardır. Bu teknikle birlikte dağıtık hesaplama sistemini de kullanarak iş yükünü parçalara bölmüş ve büyük boyutlu verileri işleyerek daha hızlı sonuçlara ulaşmışlardır.

Yıldırım, (2019) çalışmasında; veri madenciliği tekniklerinin firmalara sağladığı değerlerden biri olan müşteri sadakatini sağlama amacı ile müşteri kayıtlarını kullanarak müşteri segmentasyonu çalışması yapmıştır. Oluşturulan müşteri kümeleri için geri kazanma ve müşteri sadakatini artırma amacı ile birlikte kuralları analizi kullanmıştır. Bu analiz ile kurulan modellerin sonuçlarına göre hedef müşteri kitlesini ve gelecek çalışmalar için pazarlama stratejileri önermiştir.

Rençber ve Özdemir, (2019) çalışmalarında; Almanya ve Türkiye'deki veri uzmanı olarak çalışan bireylerin LinkedIn profillerindeki eğitim bilgileri, çalışma geçmişleri ve yetenekleri veri madenciliği yöntemlerinden RFM analizi kullanılarak elde edilen bilgilerle istatistiksel analizler yapılmıştır. Almanya ve Türkiye'deki veri uzmanlarının profilindeki bilgiler karşılaştırılarak veri alanında çalışacak uzmanlardan beklenen kriterler belirlenmiştir. Son olarak elde edilen sonuçların, veri alanında uzmanlaşmak isteyenlere rehberlik edeceği düşünülmüştür.

Kabasakal, (2020) çalışmasında; veri madenciliği yöntemlerinden müşteri ilişkileri yöntemini kullanarak müşterilerle ilişkilerini kuvvetlendirmeyi hedefleyip müşterilere elindeki verilere istinaden puanlama belirleyip bu puanlarla göre pazarlama stratejisi oluşturmuştur.

Taşabat ve Akça, (2020) çalışmalarında; veri madenciliği yöntemlerinden RFM analizini metal sektöründe kullanarak buna istinaden de geri dönüşüm projelerinden destek almayı başararak müşterilere veri sonucuna göre indirimler ayarlamışlardır.

İncelenen çalışmalar Tablo 1'de özet olarak gösterilmiştir.

Tablo 1. RFM analizi ve Apriori Algoritması Literatür Araştırması

Yazarlar	Yıl	Açıklama	Yöntem
Agrawal, ve ark.	1993	Büyük verileri sınıflandırıp ilişkilendirilerek, gömülü kuralların keşfedilmesi	RFM analizi
Bult ve Wansbeek	1995	Müşteri profillerine göre kampanya ve promosyonların belirlenmesi	RFM analizi
Akpınar ve ark.	2000	Kütüphaneye kayıtlı olan öğrencilerin kitap alma davranışlarının analizi	Ayrılcı Hiyerarşik Kümeleme
Gao ve ark.	2004	Veri yığınlarını anlamlı hale çevirip değerlendirilmesi	Kümeleme algoritması
Salvatore ve ark.	2004	Öge kümeleri belirlenerek müşterilerin satın aldıkları ürünler arasındaki ilişkilerinin belirlenmesi	FP-Growth algoritması, Pazar-Sepet analizi

Özçakır ve Çamurcu	2007	Bir pastanenin verilerinden yararlanılarak birlikte satın alınan ürünler arasındaki ilişkinin belirlenmesi	Birliktelik Analizi
Chang ve Lai	2009	Taipei şehrini seyahate gelen turistlerin toplu taşıma araçlarını seçme konusundaki düşüncelerini araştırmak ve gelen turistlerin seyahat davranışlarının onların algılarını nasıl etkilediği analizi	Faktör analizi
Timor ve ark.	2011	Bir perakende sektöründe müşterilerin aldıkları ürünler üzerinden analizlerin yapılması	Birliktelik Kuralları Analizi ve Kümeleme Analizi
Erpolat ve ark.	2012	Otomotiv sektöründe birlikte satın alınan ürünleri tespit ederek uygulanacak kampanyaların belirlenmesi	Apriori Algoritması
Sadıqmal ve ark.	2015	Modern tıp verilerinden yararlanılarak doktorlara yardımcı olacak karar destek sistemlerinin belirlenmesi	Birliktelik Analizi
Zabkowski ve ark.	2016	Telekomünikasyon şirketinde hacizli müşterilerin borçlarının değerlendirilmesi	RFM analizi
Ateş ve Karabatak	2016	Çoklu destek değeri ile seçimlerin belirlenmesi	Birliktelik Kuralı
Sözen ve ark.	2017	Mobilya seçiminde müşterilerin tercihlerinde önemsedikleri kriterlerin belirlenmesi	Apriori Algoritması
Lai ve ark.	2018	Tayvan yatırımcılarının döviz hesaplarının değerlendirilmesi	Apriori algoritması
Yüksel ve Zontul	2019	İş yükü parçalara bölünerek büyük boyutlu verilerin hızlı işlenmesi	Sepet analizi
Yıldırım ve ark.	2019	Müşteri sadakatini sağlamak için müşteri segmentasyonu yapılması	Veri madenciliği
Rençber ve Özdemir	2019	Almanya ve Türkiye'deki veri uzmanlarının LinkedIn profillerindeki bilgilerin analizi	Veri madenciliği
Kabasakal ve ark.	2020	Müşterilere uygun pazarlama stratejileri oluşturulması	Veri madenciliği
Taşabat ve Akça	2020	Metal sektöründe müşteri analizi yaparak, analiz sonucunda indirimlerden yararlanacak müşterilerin belirlenmesi	RFM analizi

Yapılan çalışmalar genel olarak değerlendirildiğinde RFM analizi ve Birliktelik analizinin perakende, tıp, otomotiv sektörlerinde kullanımının giderek yaygınlaştığı tespit edilse de perakende sektöründe değerlendirilmesi gereken ciddi bir çalışma alanı bulunduğu görülmektedir. Bu incelemeler sonucunda, RFM analizinin K-means algoritması ile birlikte tercih edildiği gözlemlenmiştir. Fakat hem RFM analizinin hem de Apriori algoritmasının birlikte değerlendirildiği müşteri segmentasyonu çalışması bulunmamaktadır. Bu çalışma ile RFM analizi ve Apriori algoritması birlikte kullanılarak literatürdeki boşluğun doldurulması amaçlanmıştır. Çalışmanın bir diğer amacı ise, çalışma bulguları ile perakende sektöründeki şirketlerin müşterilere daha iyi hizmet vermesine katkı sağlamaktır.

3. METODOLOJİ

3.3. RFM Analizi

RFM kavramı 1995 yılında Jan Roelf Bult ve Tom Wansbeek tarafından sunularak ekonomik modellerin istatistiksel yöntemlerle birleştirilip bir pazarlama tahmini uygulaması olarak tanıtılmıştır (Bult & Wansbeek, 1995).

RFM modeli, genellikle e-ticaret perakende sektöründe riskli müşterileri kazanmak için kampanya uygulaması, bankacılık sektöründe ise kredi ve senet işlemlerinde kullanılmaktadır. Bult ve Wansbeek RFM kavramının baş harflerini Yenilik (Recency)-Sıklık (Frequency)-Para Değer (Monetary) şeklinde tanımlamıştır

Kabasakal, (2020). Yenilik, müşterinin en son ne zaman alışveriş yaptığının karşılığıdır. Son alışveriş tarihi ile bugünün tarihinin farkının alınması ile bulunmaktadır. Sıklık, müşterinin bugüne kadar hangi sıklıkla alışveriş yaptığının bir göstergesidir. Monetary ise müşterinin ne kadar harcama yaptığı anlamına gelmektedir.

RFM analizi müşterileri kümelerine ayırarak hedef kitleyi en doğru şekilde belirlemeyi amaçlamıştır. Ayrıca RFM kavramı Müşteri İlişkileri Yöntemi (CRM) modeli olarak tanımlanmıştır (Erpolat & Akça, 2020). CRM modelinde kritik müşteri kümelerine odaklanarak yüksek bir yatırım getirisi sağlamak hedeflenmiştir.

Şirketler RFM analizi yaparken sadece kar-zarar tablolarını incelemeyi, aynı zamanda hangi müşteri kümelerine daha çok yatırım yapılacağını, hangi müşterilere kendilerini hatırlatacaklarını, müşterilerini kaybetmemek için nasıl aksiyon alınabileceğini, yeni müşteri kazanmak için neler yapılması gerektiğini ya da kaybetmek üzere oldukları müşterilerini tespit ederek nasıl tedbir almaları gerektiği üzerinde çalışmalar yaparak pazarlama aktivitelerini geliştirip müşteri sadakatini sağlayabilirler (Orbak, 2022).

Müşteri sadakatini etkileyen 4 önemli faktör şunlardır:

Güven: Müşteri taleplerini karşılama, ürün kalitesi, dürüstlük ve destek gibi kavramları içermektedir.

Umursanmak: Müşteriye değerli olduğu izlenimini kazandırmak önemlidir. Böylece müşteri sadakati artmış olur.

Vazgeçilmezlik: Vazgeçilmezlik müşteri ilişkileriyle doğrudan bağlantılı olmadığı düşünülse de pazarlama ve satış ile ilişkili olduğundan bu faktör göz ardı edilemez.

Ödüllendirme: Vazgeçilmezlik faktörünü destekleyen bir faktör olup müşteri sadakatini etkileyen faktörleri analiz etmek için kullanılır (Aktepe ve ark., 2018).

3.2. Birliktelik Kuralları Analizi

Veri madenciliğinde kullanılan ilk yöntemlerden birisi de birliktelik kuralları analizidir (Agrawal ve ark., 1993). Birliktelik analizi, veri tabanında bulunan veri yığınları arasındaki bağı belirleyerek, firmaların alacakları kararlarda büyük rol oynamaktadır. Bu verilerle firmalar müşterilerin alışverişlerindeki alışkanlıklarını belirlemeye çalışır. Firmalar, tespit edilen alışveriş alışkanlıkları sayesinde etkili bir pazarlama ve satış olanağına sahip olmaktadır.

Pazar sepet analizi olarak da bilinen birliktelik kuralı analizi, müşterilerin birlikte satın aldığı ürünler hakkında bilgi vermektedir (Yıldırım, 2019). Birliktelik kuralı analizindeki amaç; alışveriş sırasında müşterilerin sepetinde bulunan ürünler arasındaki ilişkiyi bulmak, bu ilişkiyle beraber müşterilerin alışverişlerinde sergiledikleri davranışları tespit etmektir (Özçakır & Çamurcu, 2007).

Bu analizin sonucunda müşterilere düzenlenecek kampanya stratejileri, marketlerdeki ürünlerin raflarda yerleştirilmesi, mağaza düzeninin tasarımı ve raflarda birlikte sunulacak, satılacak ürünlerin tayin edilmesinde kullanılır (Alan, 2012). Perakendecilik sektöründeki firmalar bu metodu, müşterilerin bir ürünü satın aldığı anda, o ürünle birlikte sepetine başka hangi ürünü ekleyeceğini belirlemek için kullanır.

Birliktelik kuralları analizinin bir başka amacı da satılan ürünler arasındaki minimum destek ve güven oranlarının tespit edilmesidir. Güven ve destek kavramları birliktelik kuralları analizinin iki önemli ölçüsüdür. Bunlar kullanıcı tarafından belirlenen değişkenlerdir (Sadiqmal, 2015). Oluşturulan kuralın doğruluğunu ölçmek için güvenilirlik, veri tablosunda oluşturulan kuralın ne kadar sıklıkla gerçekleştiğini belirlemek için ise destek ölçütü kullanılır (Erdoğan ve ark., 2015).

$A \rightarrow B$ birlikteliği için destek ve güven değerleri aşağıdaki gibidir (Webb, 2003).

$$\text{Destek } (A \rightarrow B) = \frac{\text{sayı}(A,B)}{\text{Tüm alışverişler}} \quad (1)$$

$$\text{Güven } (A \rightarrow B) = \frac{\text{sayı}(A,B)}{\text{sayı}(A)} \quad (2)$$

A ve B ürünlerinin müşteri tarafından satın alınmasındaki ilişkinin güvenilebilir olması için her iki ölçüt değerinin oldukça yüksek olması gerekmektedir (Erpolat, 2012).

Bu ilişki yaygın olan bir örnek ile açıklanabilir: “Bira içeren %30 alışverişin, %2’si aynı zamanda çocuk bezi de içermektedir.” Bu örnekte %30 güven oranını, %2 ise bu güven oranına olan desteği açıklamaktadır (Emel ve ark., 2005).

Kuralların değerlendirilmesi için kullanılan bir başka ölçüt Lift (Kaldıraç) oranıdır. Lift oranı korelasyon analizinde kullanılarak bir kuralın ne kadar ilginç olduğunu tespit etmektedir (Ateş & Karabatak, 2017). Lift değerinin 1’ den küçük veya büyük olması ilginçliği arttırmakla birlikte “1” değerini alması ilginçliğin olmadığını göstergesidir (Jabbour ve ark., 2018).

Lift oranı aşağıdaki gibi hesaplanmaktadır.

$$\text{Lift } (A \rightarrow B) = \frac{\text{destek } (A \cap B)}{\text{destek } (A) * \text{destek } (B)} \quad (3)$$

Birliktelik kuralı analizi için Conviction (Kanaat) ve Leverage (Kaldıraç) ölçütleri de kullanılmaktadır.

Conviction ölçütü A elemanı varken, B elemanı olmadan görülme olasılığı olarak hesaplanır. Hesaplama sonucunda Conviction değeri 1 ise A ve B elemanları birbiriyle ilişkisinin olmadığını, Conviction değeri 1’den farklı ise bağıntılı bir kural olduğunun göstergesidir (Yüksel & Zontul, 2019).

$$\text{Conviction } (A \rightarrow B) = \frac{1 - \text{destek}(B)}{1 - \text{güven}(A,B)} \quad (4)$$

Leverage ölçütü ise müşterinin satın aldığı ürünler üzerinden A ve B ürünlerinin beraber satın alınmasının, A ve B'nin birlikte satın alınmamasından ne kadar fazla olduğunun göstergesidir (Lia & Lu, 2018).

$$\text{Leverage (A} \rightarrow \text{B)} = P(A \cap B) - (P(A) * P(B)) \quad (5)$$

Birliktelik kuralına bağlı olarak geliştirilen bazı algoritmalar şunlardır; AIS (Agrawal ve ark., 1993), Apriori (Agrawal & Srikant, 1994), CHARM (Zaki & Hsiao, 2002), RARM (Das ve ark., 2001). Bu algoritmalar içerisinde ilk olanı AIS, en bilineni ise Apriori algoritmasıdır (Ayberkin & Özen, 2019).

3.2.1. Apriori algoritması

Apriori algoritması, olayların birlikte gerçekleşme durumunu anlatan veri madenciliği yöntemlerinden biridir (Sözen ve ark., 2017). Bu yöntem ismini bir önceki adımdaki verileri kullandığından dolayı “prior” kelimesinden almaktadır (Agrawal & Srikant, 1994).

Apriori algoritması, temelinde birliktelikleri keşfetmek için tekrarlayan bir niteliğe sahiptir (Han & Kamber, 2006). Birliktelik kuralı analizinin ilk aşaması için kullanılan Apriori Algoritması, sık tekrarlanan öğeler madenciliğinde en çok kullanılan algoritmadır. Bu algorithmada özellikler ve veri, Boolean ilişki kuralları ile değerlendirilir (Gao, 2004).

Bununla birlikte veri setinde sık geçen öğe kümelerinin belirlenmesinde kullanılır. Elde edilen küme bir sonraki adımda tüm alt kümeleri bulmak için kullanılır. Alt kümelerin her birinin bulunabilmesi için veri seti detaylı bir şekilde taranmalıdır. Bu taramalar esnasında analiz yapılacak alanı daraltmak ve verimliliği artırmak için Apriori algoritması kullanılır (Han ve ark., 2011). Bu özelliğe göre eğer k-öge kümesi minimum destek ölçütü değerini sağlıyorsa, oluşturulan bu kümenin alt kümeleri de minimum destek ölçütünü sağlar. (Salvatore ve ark., 2004). Her tarama bir önceki taramada önemli görülen veriden başlar. Bu önemli görülen verilerden gruplar oluşturulur. Bu tarama süreci yeni nesne kümelerini bulana kadar devam eder (Emin ve ark., 2015). Taramanın sonucunda hangi veri kümesi önemli olduğu belirlenir. (Çöllüoğlu ve ark., 2013)

4. UYGULAMA


Bu çalışmada, gıda perakende sektöründe varlığını gösteren firmadan alışveriş yapan müşterilerin alışveriş kayıtları ele alınarak RFM analizi ile Apriori algoritması kullanılmıştır. Yapılan analizde, konu olan firmanın müşterilerini segmente ederek yapılacak kampanyalar için müşteriler önceliklendirip, müşterilerin satın aldıkları ürünlerin arasındaki ilişkiler belirlenerek çeşitli pazarlama stratejileri geliştirilip önerilerde bulunulması amaçlanmıştır. Örneklem olarak Türkiye'nin öncü gelen gıda perakende sektöründe hizmet veren bir firmanın SAP programı yardımıyla 01.01.2022-31.10.2022 tarihleri arasındaki on aylık sürede alışveriş yapan 18.617 tane müşterinin, 61.712 adet satış kaydı kullanılmıştır. Müşterilere ait veri seti; her müşteriye ait bir kimlik numarası, sipariş numarası, alışverişin yapıldığı tarih, satın alınan ürünün adı, kodu, fiyatı ve hangi üründen kaç adet alındığına dair kayıtlardan oluşmaktadır.

Analizler için Python programı ile öncelikle RFM analizi yapılarak müşterilerin satın alma alışkanlıklarını ölçüp müşteri segmentleri belirlenmiştir. Daha sonra birliktelik kurallarının elde edilmesi için Apriori algoritması kullanılarak satın alınan ürünler arasındaki ilişkiler analiz edilmiştir. Şekil 1' de müşteri alışveriş kayıtlarının olduğu ana tablonun bir kesiti gösterilmektedir.

	A	B	C	D	E	F	G
1	Date	Invoice	Custom	Produ	Stock	Name	Price
2	01.01.2022	9185800575921383	172586	1	22000398	KonsantreYumuşatıcıLovely1440ml	24.9
3	01.01.2022	9185800575921383	172586	1	12000013	YarımYağlıSüt1L	6.5
4	01.01.2022	9185800575921383	172586	1	20000948	DomatesKokteylPaket-kg	11.89
5	01.01.2022	9185806105050997	634242	1	22001891	BionetKlozetBlokÇeşitleri2Adet	8.95
6	01.01.2022	9185811917077294	764951	6	13000091	Su1,5L	9.24
7	01.01.2022	9185811182437974	763529	2	25001890	AlışverişPoşetiTekli	0.5
8	01.01.2022	9185811182437974	763529	4	12002640	Süt200ml	9
9	01.01.2022	9185811182437974	763529	1	22001968	ÇamaşırSuyuUltra1250Ml	9.5
10	01.01.2022	9185811182437974	763529	1	22000468	YağÇözücüLimon750ml	7.9
11	01.01.2022	9185811182437974	763529	1	28000573	DorbiHamurKabartmaTozu10x10g	2.75
12	01.01.2022	9185811182437974	763529	1	28000575	DorbiKakao50g	2.75
13	01.01.2022	9185811182437974	763529	1	28000574	DorbiVanilya5x10g	2.5
14	01.01.2022	9185811182437974	763529	1	18002041	GalleSirkeElma750ml	3.5
15	01.01.2022	9185811182437974	763529	1	18002047	GalleTurşuSalatalık680g	6.5
16	01.01.2022	9185811182437974	763529	1	25001550	KoroplastKesilmişYağlıPişirmeKağıdı16Adet	13.1
17	01.01.2022	9185811182437974	763529	1	28000193	TamBuğdayUnluEkmek350g	6.15
18	01.01.2022	9185811182437974	763529	1	14001902	PirinçBaldoPirinçBaldo1000g	14.95
19	01.01.2022	9185811182437974	763529	3	13000090	Su5L	13.5
20	01.01.2022	9185811182437974	763529	9	17000192	ÜlkerAlbeniBarÇikolataKaramelli40g	15.3
21	01.01.2022	9185788901911247	333961	3	25001890	AlışverişPoşetiTekli	0.75
22	01.01.2022	9185800209619938	487986	3	25001890	AlışverişPoşetiTekli	0.75
23	01.01.2022	9185808649224398	800144	2	25001890	AlışverişPoşetiTekli	0.5
24	01.01.2022	9185808649224398	800144	1	20000812	ArmutDeveci-kg	5.06
25	01.01.2022	9185800209619938	487986	2	14001937	MakarnaBurgu500g	6.9
26	01.01.2022	9185800209619938	487986	2	14001936	MakarnaFiyonk500g	6.9

Şekil 1. Müşteri Alışveriş Kayıtlarının Bulunduğu Veri Setinden Bir Kesit

Python programı yalnızca '.csv' uzantılı dosyaları kabul ettiğinden dolayı, Excel'de oluşturulmuş veri seti tablosu .csv formatında kaydedilmiştir. Sonrasında Şekil 2' de gösterildiği gibi veri seti programa yüklenmiştir.



Şekil 2. Veri Dosyasının Kütüphaneye Yüklenmesi

Çalışmanın ilk kısmı olan RFM skorlarının belirlenmesinde gerçekleşen her bir satış “Verilen Sipariş Tarihi”, “Sipariş Numarası”, “Müşteriyi ID”, “Ürün Sayısı”, “Ürünün Kodu”, “Ürünün Adı”, ”Satış Tutarı” olarak analiz çalışması için girdi olarak tanımlanmıştır. Tanımlanan girdiler Şekil 3’de gösterilmiştir.

	InvoiceDate	Invoice	Customer ID	Quantity	StockCode	Description	Price	TotalPrice
0	2022-01-01	9185800575921380	172586	1	22000398	BingoKonsantreYumusaticiLovely1440ml	24.90	24.90
1	2022-01-01	9185800575921380	172586	1	12000013	BirsahYarimYagliSut1L	6.50	6.50
2	2022-01-01	9185800575921380	172586	1	20000948	DomatesKokteylPaket-kg	11.89	11.89
3	2022-01-01	9185806105050990	634242	1	22001891	BionetKlozetBlokCesitleri2Adet	8.95	8.95
4	2022-01-01	9185811917077290	764951	6	13000091	Su1,5L	9.24	55.44

Şekil 3. Python Veri Görseli

RFM analizinde Şekil 3’de belirtilen alışveriş kayıtlarına göre her bir müşteri için recency, frequency ve monetary değerleri baz alınarak skor ataması yapılmıştır. Belirlenen bu üç skor farklı yöntemlerle birleştirilerek RFM skoru oluşturulmuştur. Oluşturulan RFM skorları Şekil 4’ de gösterilmiştir.

Customer ID	Monetary	Recency	Frequency	Freq_Tile	Rec_Tile	Mone_Tile	Score
139483	336.35	23	1	1	1	2	112
656693	198.80	23	1	1	1	2	112
1167519	293.10	23	1	1	1	2	112
967503	2434.39	23	5	5	1	5	155
622899	17817.53	23	66	5	1	5	155

Şekil 4. Müşteri Skor Ataması

Sonuç olarak her müşteri için belirlenen recency, frequency, monetary ve bu üç değer birleştirilmesiyle oluşturulan RFM skorlarına göre müşteri segmentleri belirlenmiştir. Belirlenen müşteri segmentleri Şekil 5’deki gibidir.

```

seg_map = {
    r'[1-2][1-2]': 'Hibernating',
    r'[1-2][3-4]': 'At Risk',
    r'[1-2]5': 'Can't Loose',
    r'3[1-2]': 'About to Sleep',
    r'33': 'Need Attention',
    r'[3-4][4-5]': 'Loyal Customers',
    r'41': 'Promising',
    r'51': 'New Customers',
    r'[4-5][2-3]': 'Potential Loyalists',
    r'5[4-5]': 'Champions'
}

```

Customer ID	Monetary	Recency	Frequency	Freq_Tile	Rec_Tile	Mone_Tile	Score	Segment
139483	336.35	23	1	1	1	2	112	Hibernating
656693	198.80	23	1	1	1	2	112	Hibernating
1167519	293.10	23	1	1	1	2	112	Hibernating
967503	2434.39	23	5	5	1	5	155	Can't Loose
622899	17817.53	23	66	5	1	5	155	Can't Loose

Şekil 5. Müşteri Kümelerini Belirleme

Yapılan RFM analizi sonucunda müşteriler 10 farklı segmente ayrılmış olup Şekil 6'da gösterilmiştir.

Segment	Recency			Frequency			Monetary		
	mean	count	max	mean	count	max	mean	count	max
Need Attention	160.426291	1879	189	1.000000	1879	1	379.282491	1879	27509.78
New Customer	83.201021	2547	131	2.781311	2547	4	1257.545842	2547	27031.90
Champions	67.572530	2854	131	11.543798	2854	132	7249.472207	2854	1064178.67
At Risk	296.770588	170	345	3.411765	170	9	1375.047471	170	7038.40
Loyal Customers	89.141404	2065	131	1.000000	2065	1	442.836291	2065	12269.46
Potential Loyalist	179.515416	1719	267	4.543339	1719	28	2203.576719	1719	170993.30
Can't Loose	159.002755	726	189	2.000000	726	2	811.482672	726	9663.75
Hibernating	319.511170	3044	366	1.000000	3044	1	358.645618	3044	10397.92
Promising	257.071140	1237	357	2.000000	1237	2	790.088941	1237	7655.60
About to Sleep	228.655303	2376	267	1.000000	2376	1	432.630345	2376	9613.08

Şekil 6. Müşteri Kümeleri

Çalışmanın ikinci aşamasında ise Apriori algoritması kullanılarak müşterilerin satın aldıkları ürünler arasındaki ilişkiler analiz edilmiştir. Böylelikle çalışmada kampanyaların verimliliğini önceden tespit edilmesi sağlanmıştır.

Apriori algoritmasının çalışması için birliktelik kuralı kütüphanelerinin Python programına dâhil edilmesi gerekmektedir. Şekil 7' de verildiği gibi python kodları ile süreç başlatılmıştır.

```
[38]: !pip install mlxtend

Requirement already satisfied: mlxtend in c:\users\pcx\anaconda1\lib\site-packages (0.21.0)
Requirement already satisfied: numpy>=1.16.2 in c:\users\pcx\anaconda1\lib\site-packages (from mlxtend) (1.21.5)
Requirement already satisfied: scipy>=1.2.1 in c:\users\pcx\anaconda1\lib\site-packages (from mlxtend) (1.9.1)
Requirement already satisfied: joblib>=0.13.2 in c:\users\pcx\anaconda1\lib\site-packages (from mlxtend) (1.1.0)
Requirement already satisfied: matplotlib>=3.0.0 in c:\users\pcx\anaconda1\lib\site-packages (from mlxtend) (3.5.2)
Requirement already satisfied: pandas>=0.24.2 in c:\users\pcx\anaconda1\lib\site-packages (from mlxtend) (1.4.4)
Requirement already satisfied: scikit-learn>=1.0.2 in c:\users\pcx\anaconda1\lib\site-packages (from mlxtend) (1.0.2)
Requirement already satisfied: setuptools in c:\users\pcx\anaconda1\lib\site-packages (from mlxtend) (63.4.1)
Requirement already satisfied: pillow>=6.2.0 in c:\users\pcx\anaconda1\lib\site-packages (from matplotlib>=3.0.0->mlxtend) (9.2.0)
Requirement already satisfied: python-dateutil>=2.7 in c:\users\pcx\anaconda1\lib\site-packages (from matplotlib>=3.0.0->mlxtend) (2.8.2)
Requirement already satisfied: kiwisolver>=1.0.1 in c:\users\pcx\anaconda1\lib\site-packages (from matplotlib>=3.0.0->mlxtend) (1.4.2)
Requirement already satisfied: fonttools>=4.22.0 in c:\users\pcx\anaconda1\lib\site-packages (from matplotlib>=3.0.0->mlxtend) (4.25.0)
Requirement already satisfied: packaging>=20.0 in c:\users\pcx\anaconda1\lib\site-packages (from matplotlib>=3.0.0->mlxtend) (21.3)
Requirement already satisfied: pyparsing>=2.2.1 in c:\users\pcx\anaconda1\lib\site-packages (from matplotlib>=3.0.0->mlxtend) (3.0.9)
Requirement already satisfied: cycloper>=0.10 in c:\users\pcx\anaconda1\lib\site-packages (from matplotlib>=3.0.0->mlxtend) (0.11.0)
Requirement already satisfied: pytz>=2020.1 in c:\users\pcx\anaconda1\lib\site-packages (from pandas>=0.24.2->mlxtend) (2022.1)
Requirement already satisfied: threadpoolctl>=2.0.0 in c:\users\pcx\anaconda1\lib\site-packages (from scikit-learn>=1.0.2->mlxtend) (2.2.0)
Requirement already satisfied: six>=1.5 in c:\users\pcx\anaconda1\lib\site-packages (from python-dateutil>=2.7->matplotlib>=3.0.0->mlxtend) (1.16.0)
```

Şekil 7. Pip Install Komutu ile Paket Program Yükleme

Apriori algoritması, binary (1, 0) ilişki kuralları içerdiği için müşterinin sepetinde ürün varsa o ürünün adetine bakılmaksızın 1, eğer müşterinin sepetinde ürün yoksa matriste 0 değerini alır. Oluşturulan matris Şekil 8’de gösterilmiştir.

Description	.PitaEkmegi4'lu	10"DijitalYaziTahtasi	10'luGezenTavukYumurtasiMBoy(53-62g)	10'luOmegaYumurtaMBoy(53-62g)	10'lugezenTavukYumurtasiMBoy(53-62g)
Customer ID					
3599	0	0	0	0	0
3784	0	0	0	0	0
7423	0	0	0	0	0
8701	0	0	0	0	0
10427	0	0	0	1	0

5 rows x 7486 columns

Şekil 8. Birliktelik Analizi için Oluşturulan Matris

Apriori algoritması ile en çok satılan ürünler tespit edilip satılan ürün listesi Şekil 9’ da gösterilmiştir.

support	itemssets
0.181662	(Patates-kg)
0.156255	(Sogan-kg)
0.151313	(Ekmek1Adet)
0.126766	(Maydonoz-Adet)
0.119300	(MuzYerli-kg)
0.116184	(Limon-kg)
0.114304	(30'luYumurtaMBoy(53-62g))

Şekil 9. Support Değerlerinin Hesaplanması

Çalışma sonunda elde edilen çıktılara ait birliktelik kurallarının bir kısmı Şekil 10'da verilmiştir.

antecedents	consequents	antecedent support	consequent support	support	confidence	lift	leverage	conviction
(Sogan-kg)	(Patates-kg)	0.156255	0.181662	0.113284	0.724991	3.990883	0.084898	2.975682
(Patates-kg)	(Sogan-kg)	0.181662	0.156255	0.113284	0.623596	3.990883	0.084898	2.241591
(Limon-kg)	(Patates-kg)	0.116184	0.181662	0.071870	0.618585	3.405146	0.050764	2.145534
(Maydonoz-Adet)	(Patates-kg)	0.126766	0.181662	0.070044	0.552542	3.041597	0.047015	1.828862
(30'luYumurtaMBoy(53-62g))	(Patates-kg)	0.114304	0.181662	0.050438	0.441259	2.429014	0.029673	1.464612

Şekil 10. Birliktelik Analizi Tablosu

Elde edilen sonuçlar ile support, confidence ve lift değerleri Pazar-Sepet Analizinde çok önemli fikirler vermektedir. Support değeri, satın alınan ürünlerin veri seti içerisindeki oranını, confidence değeri satın alınan ürünler arasındaki ilişkiyi ve lift değeri, bir gruptaki ürünlerin ne kadar birlikte satın alındığını göstermektedir (Erpolat, 2012).

Güven (confidence) ve destek (support) değerinin yüksek olması tek bir kriter olarak birliktelik kuralının önemini ortaya koymayabilir. Bu nedenle lift değeri de dikkate alınmalıdır. Kuvvetli ilişkiler için lift değerinin 1' in üzerinde olması beklenir. (Ateş & Karabatak, 2017). Bu veriler doğrultusunda;

Şekil 10'da kırmızı ile işaretlenen kurala göre; soğanın alışverişte tek başına görülme olasılığı %15'dir. Patatesin alışverişte tek başına görülme olasılığı %18'dir. 100 alışverişin 11'inde mutlaka soğan ve patates beraber satın alınmıştır. Soğan satıldığında patatesin de satılma oranı %72 olarak sonuçlandırılmıştır. Soğanın satılması patatesin satın alınma olasılığını 3,99 kat arttırmaktadır.

Sarı ile işaretlenen kurala göre ise; 30'lu yumurtanın alışverişte tek başına görülme olasılığı %11'dir. Patatesin alışverişte tek başına görülme olasılığı %18'dir. 100 alışverişin 5'inde mutlaka yumurta ve patates beraber satın alınmıştır. Yumurta satıldığında patatesin de satılma oranı %44 olarak sonuçlandırılmıştır. Yumurtanın satılması patatesin satın alınma olasılığını 2 kat arttırmaktadır.

Yapılan analiz neticesinde birliktelik ilişkileri yüksek olan ürünler için kampanyalar düzenlenerek şirketin cirosu artırılır.

5. SONUÇ VE ÖNERİLER

Günümüzde perakende sektöründe yaşanan rekabet gün geçtikçe artmaktadır. Yaşanan yoğun rekabet ortamında perakendecilerin hayatta kalabilmelerinin yolu sahip oldukları müşteri kitlelerini iyi tanımalarıdır. Firmaların müşteri kitlelerini net bir biçimde belirlemesi rekabetin etkisini çok hissetmemekle birlikte sektördeki faaliyetini devam ettirmesini sağlar.

Müşteri kitlelerinin belirlenmesinde perakende firmalarının kolaylıkla uygulayabilecekleri, veri odaklı müşteri alışveriş davranışlarını inceleyen, popüler, ucuz ve güvenilir bir teknik olan RFM analizi kullanılır (Zabkowski, 2016). Perakende firmalarının sahip oldukları müşterilere ait verilerin kullanılarak RFM analizi ile anlamlı hale getirilmesi müşteri kümelerinin daha net bir şekilde yapılmasını sağlayacaktır. RFM analizi ile müşteriler üç temel kategoride puanlanarak değerlendirilir: müşterinin en son ne zaman satın alma işlemi gerçekleştirdiği, müşterinin ne sıklıkla alışveriş yaptığını ve müşterinin ne kadar tutarda harcama yaptığını bakılarak kümelere ayırıp, bu kümelere uygun isimler verilmiştir. Bu sayede kümelere ayrılmış müşterilere farklı davranılarak uygulanacak tutundurma çabaları daha etkin bir hale gelecektir. Ancak, müşterilerin yalnızca belirli kümelere ayrılması yeterli olmayacaktır. Müşterilerin hangi ürünleri tercih ettiklerinin tespit edilmesi perakende firmaları açısından özellikle ürünlerin satışlarını arttırmada önemli bir faktördür.

Bu çalışmada bir gıda sektöründe hizmet veren perakende firmasına ait müşteri verileri kullanılarak, RFM analizi ile müşteri portföyü oluşturulmuştur. Oluşturulan müşteri portföyü ile müşteri sadakati arttırılmıştır. Apriori Algoritması kullanarak da müşterilerin satın alma alışkanlıkları belirlenerek karlılığı arttıracak kampanya ve değer yaratan stratejiler sunulmuştur.

Araştırma kapsamında firmadan alınan veriler aylara göre sipariş tarihi, sipariş numarası, müşteri id, ürün sayısı, ürünün kodu, ürünün adı, satış tutarı bilgilerden oluşmaktadır. Öncelikle veri dosyası, veri madenciliği yazılımında kullanılabilecek hale dönüştürülmüştür. Düzenlenen verilerde toplam 18617 müşteriye ait 61712 tane alışveriş hareketi olduğu görülmüştür. Dönüştürülen veriler Python yazılımında veri madenciliği yöntemi kullanılarak analiz edilmiştir.

Çalışma iki aşamadan oluşmaktadır; birinci aşamasında 18617 müşteriye ait alışveriş kayıtları kullanılarak gerçekleştirilen RFM analizi ile ilk olarak müşterilerin her birinin alışveriş kayıtlarına göre Recency, Frequency ve Monetary değerleri bulunmuştur. Recency, müşterinin son alışverişinden bugüne kadar geçen süre bilgisini verir. Bugünün tarihi ile son satın alma tarihi arasındaki farkı ifade eder. Frequency, müşterinin ne sıklıkla alışveriş yaptığını gösteren metriktir. Monetary ise müşterinin alışverişinde yaptığı harcamalarının toplamıdır. Bulunan RFM değerleri 1 ile 5 arasında puanlanarak her bir müşteriye skor ataması yapılmıştır. Yapılan skor atamalarına göre müşteriler 10 farklı segmente ayrılmıştır.

Çalışmanın sonuçlarına göre, sepet tutarları en yüksek olan müşteri gruplarının “Champions” ve “Potential Loyalist” olduğu görülmektedir. Şirket tarafından bu müşterileri kaybetmemek ve şirketle olan ilişkilerini güçlendirecek çalışmaların yapılması önemlidir. Bu kümede bulunan müşterilere çeşitli kampanyalar ve özel indirimler yapılarak ödüllendirilebilir. Bununla birlikte özel günlerde hediyeler verilerek müşterinin sadakati arttırılabilir.

Yüksek müşteri sayısı bulunduran “New Customer” kümesindeki müşterilerin alışveriş sıklıklarını arttırmak ve sadakati arttırmak için “Yeni Müşteri Alıştırma” programları düzenlenerek şirketin ürün ve uygulamaları tanıtılabilir. Şirket tarafından ilgili kümedeki müşterilere kendilerini hatırlatacak e-posta gönderilerek ya da telefonla ulaşarak ürün ve kampanyaların tanıtılması sağlanabilir.

“Can’t Loose” kümesi çok uzun süre önce alışveriş yapmış fakat alışveriş sıklığı yüksek olan müşteri kümesidir. Bu müşteri kümesinin şirketi terk etme olasılığı yüksek olduğu için bu müşteri kümesine özel çeşitli sadakat çalışmaları yapılarak tekrar kazanımları sağlanmalıdır. Aynı şekilde “Need Attention” ve “About to sleep” kümesindeki müşterilere özel teklifler sunulabilir ya da geçmiş sepetleri incelenerek ürün önerilerinde bulunup tekrar alışveriş yapmaları için teşvik edilebilir.

“Hibernating” kümesi, uzun zamandır alışveriş yapmamış ve şirketi çok iyi tanımayan müşterileri bulundurmaktadır. Bu kümedeki müşteriler için özel gösterilebilecek reklam çalışmaları yapılabilir. Aynı zamanda şirketi tanımaları için ürünleri tanıtan ve içerisinde kupon kodu olan e-mail gönderilebilir.

“At Risk” kümesi, şirketi tanıyan fakat uzun zamandır alışveriş yapmayan müşterileri bulundurmaktadır. Yeni müşterileri kazanmak maliyetli olduğu için bu müşterileri elde tutmak gerekmektedir. Şirket bu müşterilere kendini hatırlatacak e-mail veya sms atarak indirim kuponu tanımlayabilir.

“Loyal Customer” kümesi, alışveriş sıklığı yüksek fakat sepet tutarı düşük olan müşterileri içermektedir. Bu müşteri grubunun sepet tutarını arttırmak için popüler ürünler indirimli olarak sunulabilir.

“Promising” kümesi, yakın zamanda alışveriş yapan müşterileri içermektedir. Bu kümedeki müşteriler için özel teklifler sunulabilir sık sık ve yüksek tutarda alışveriş yapmaları sağlanabilir.

“About to Sleep” kümesi, uzun süredir alışveriş yapmayan müşterileri bulundurmaktadır. Bu kümede yüksek tutarda alışveriş yapan müşterilere özellikle dikkat etmek gerekir. Bu müşteri kümesine özel indirim teklifleri sunulup ürün önerilerinde bulunulabilir.

İkinci aşamada ise ürünler arasındaki satış ilişkilerinin belirlenmesi ile birlikte firma tarafından depolanan alışveriş kayıtları ışığında anlamlı bilgiler elde edilmesi amaçlanmıştır. Bu amaçla müşterilerin alışveriş kayıtları veri madenciliği yöntemlerinden biri olan birliktelik kurallarından apriori algoritması ile incelenmiştir. Yapılan analiz sonucunda elde edilen sonuçlardan yola çıkarak, şirketin kar marjının yükseltilmesi için birbiriyle güçlü satış ilişkisi bulunan ürünler üzerinden reklam stratejileri geliştirilebilir veya çeşitli promosyonlar hazırlanabilir.

Yazarların Katkısı

Yazarların makaleye katkıları eşit orandadır.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

KAYNAKÇA

Agrawal, R., Imieliński, T. & Swami, A. (1993). Mining association rules between sets of items in large databases. *SIGMOD Rec.*, 22(2), 207–216. <https://doi.org/10.1145/170036.170072>.

- Agrawal, R. & Srikant, R. (1994, 12-15 Eylül). *Fast algorithms for mining association rules in large databases*. Proceedings of the 20th International Conference on Very Large Data Bases, Santiago de Chile.
- Akpınar, H. (2000). Veri Tabanlarında Bilgi Keşfi ve Veri Madenciliği. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 29(1), 1-22.
- Aktepe, C., Baş M. & Tolon M. (2018). Müşteri ilişkileri yönetimi. *Detay Yayıncılık*, Ankara.
- Alan, M. A., (2012). Veri madenciliği ve lisansüstü öğrenci verileri üzerine bir uygulama. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, 33, 165-174.
- Ateş, Y. & Karabatak, M. (2017). Nicel birliktelik kuralları için çoklu minimum destek değeri. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 29(2), 57-65.
- Ayberkin, D. & Özen, Ü. (2021). Blokzincir teknolojisinin dijital reklam ve pazarlama sektöründe kullanımı: Modelleme çalışması ve kavramsal bir çerçeve. *Journal of Business in The Digital Age*, 4(2), 165-171. DOI: 10.46238/jobda.1021911.
- Berger, D.P. & Nasr, N.I. (1998). Customer lifetime value: Marketing models and applications, *Journal of Interactive Marketing*, 17-30.
- Blattbergs, R. C. & Malthouse, E.C. (2009). Customer lifetime value: Empirical generalizations and some conceptual questions. *Journal of Interactive Marketing*, 23, 157-168.
- Bult, J. R. & Wansbeek, T. (1995). Optimal Selection for Direct Mail. *Marketing Science*, 14(4), 378-394.
- Das, A., Ng, W.K. & Woon, Y.K. (2001, 5-10 Kasım). *Rapid association rule mining*. Proceedings of the 2001 ACM CIKM International Conference on Information and Knowledge Management, Atlanta, Georgia, USA.
- Chang, H.H. & Lai, T.Y. (2009). The Taipei Mrt (mass rapid transit) tourism attraction analysis from the inbound tourists' perspectives. *Journal of Travel & Tourism Marketing*, 26(5-6), 445-461.
- Emel, G.G., Taşkın, Ç. & Tok, A. (2005). Pazarlama Stratejilerinin Oluşturulmasında Bir Karar Destek Aracı: Birliktelik Kuralı Madenciliği. *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 7(3), 30-59.
- Erdoğan, N.K., Gülcan, B. & Karamaşa, Ç. (2015, 31 Ekim). *Birliktelik kuralları ve uygulamaları: Literatür taraması (2000-2014)*. 13.Uluslararası Türk Dünyası Sosyal Bilimler Kongresi, Bakü, Azerbaycan.
- Erpolat, S. (2012). Otomobil yetkili servislerinde birliktelik kurallarının belirlenmesinde Apriori ve FP-Growth Algoritmalarının karşılaştırılması. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 12(2), 137-146.
- Erpolat Taşabat, S. & Akca, E. (2020). Recycling project With RFM analysis in industrial material sector. *Sigma: Journal of Engineering & Natural Sciences*, 38(4), 1681-1692.

- Gao, W. (2004). *A hierarchical document clustering algorithm* [MSc Thesis]. Dalhousie University, Halifax, Nova Scotia.
- Han, J. & Kamber, M. (2006). *Data mining: Concepts and techniques*, 2nd. *University of Illinois at Urbana Champaign: Morgan Kaufmann*.
- Hand, D.J. (1998). Data mining: Statistics and more? *The American Statistician*, 52(2), 112-118.
- Jabbour, S., El Mazouri, F.E. & Sais, L. (2018). Mining negatives association rules using constraints. *Procedia Computer Science*, 127, 481-488.
- Kabasakal, İ. (2020). Customer segmentation based on recency frequency monetary model: A case study in E-retailing. *Bilişim Teknolojileri Dergisi*, 13(1), 47-56.
- Kumar, V. & Reinartz, W. (2012). *Customer relationship management: Concept, strategy and tools*. *Springer Science & Business Media*.
- Lai, C., Lu & Jin. (2018). Evaluating the efficiency of currency portfolios constructed by the mining association rules. *Asia Pacific Management Review*, 23(3), 161-234.
- Orbak, İ. (2022). Perakende sektöründe kullanılan teknolojik ürünlerin müşteri ilişkileri üzerindeki rolünün incelenmesi. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 27(2), 663-680. DOI:10.17482/uumfd.1092745.
- Özçakır, F. C. & Çamurcu, A.Y. (2007). Birliktelik kuralı yöntemi için bir veri madenciliği yazılımı tasarımı ve uygulaması. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 6(12), 21-37.
- Rençber, S. Ö. & Özdemir, A. (2019). Almanya ve Türkiye'deki büyük veri uzmanlarının eğitim ve yeteneklerinin karşılaştırılması: Linked-in veri madenciliği uygulaması. *Veri Bilimi*, 2(1), 35-43.
- Sadiqmal, F. (2015). *Implementation of some medical data using Apriori algorithm* [Master Thesis]. Sakarya University, Institute of Science and Technology, Sakarya.
- Salvatore, O., Perego, R. & Silvestri, C. (2004). A new algorithm for gap constrained sequence mining. *SAC '04 Proceedings of the 2004 ACM Symposium on Applied Computing*, 540-547.
- Sözen, E., Bardak, T., Peker, H. & Bardak, S. (2017). Apriori algoritması kullanılarak mobilya seçiminde etkili olan faktörlerin analizi. *İleri Teknoloji Bilimleri Dergisi*, 6(3), 679-684.
- Timor, M., Ezerçe, A. & Gürsoy, U. (2011). Müşteri profili ve alışveriş davranışlarını belirlemede kümeleme ve birliktelik kuralları analizi: Perakende sektöründe bir uygulama. *Yönetim Dergisi: İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadi Enstitüsü*, 22(68), 128-147.
- Tsao, YC, Raj, PVRP. & Yu, V. (2019). Müşteri segmentasyonu ve panik satın alma davranışı dikkate alınarak farklı gramaj ve markalarda ürün değişimi. *Endüstriyel Pazarlama Yönetimi*, 77, 209-220.
- Webb, G.I. (2003). Association rules. In Nong Ye (Edt.), *The handbook of data mining*. *Lawrence Erlbaum Associates, Inc.* New Jersey.

- Wu, W. T., Li, Y. J., Feng, A. Z., Li, L., Huang, T., Xu, A. D. & Lyu, J. (2021). Data mining in clinical big data: the frequently used databases, steps, and methodological models. *Military Medical Research*, 8(1), 1-12.
- Yıldırım, B. (2019). *Modern perakendecilik sektöründe veri madenciliği tekniklerinin uygulanması* [Yüksek Lisans Tezi]. İstanbul Üniversitesi-Cerrahpaşa, Lisansüstü Eğitim Enstitüsü, İstanbul.
- Yüksel, T. & Zontul, M. (2019). Dağıtık sistemlerde birliktelik kuralları ile sepet analizi. *AURUM Journal of Engineering Systems and Architecture*, 3 (1), 65-77.
- Zabkowski, T.S. (2016). RFM approach for telecom insolvency modeling. *Kybernetes*, 45(5), 815-827. <https://doi.org/10.1108/K-04-2015-0113>
- Zaki, M. & Hsiao, C.J. (2002, 11-13 Nisan). *CHARM: An efficient algorithm for closed itemset mining*. Proceedings of the Second SIAM International Conference on Data Mining, Arlington, VA, USA.