T.C
MARMARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
SAYISAL YÖNTEMLER BİLİM DALI

PAZARLAMA SEGMENTASYON MODELLERİNİN KARŞILAŞTIRILMASI ÜZERİNE BİYOTEKNOLOJİ SEKTÖRÜNDE BİR UYGULAMA

YÜKSEK LİSANS TEZİ

EBRU SARIOĞLU

İSTANBUL, 2024

T.C
MARMARA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
SAYISAL YÖNTEMLER BİLİM DALI

PAZARLAMA SEGMENTASYON MODELLERİNİN KARŞILAŞTIRILMASI ÜZERİNE BİYOTEKNOLOJİ SEKTÖRÜNDE BİR UYGULAMA

YÜKSEK LİSANS TEZİ

EBRU SARIOĞLU

Tez Danışman: DOÇ.DR. MEHMET NURİ İNEL

Jüri Üyesi: Prof. Dr. Hakan YILDIRIM

Jüri Üyesi: Doç.Dr. Serkan ETİ

İSTANBUL, 2024

ÖZET

PAZARLAMA SEGMENTASYON MODELLERİNİN KARŞILAŞTIRILMASI ÜZERİNE BİYOTEKNOLOJİ SEKTÖRÜNDE BİR UYGULAMA

Günümüzde artan rekabet, firmaların müşteri bağlılığını artırmak için daha fazla çaba sarf etmesini gerektirmektedir. Birçok firma, müşteri ilişkileri yönetimi (CRM) uygulamalarına önemli yatırımlar yaparak müşteri ihtiyaçlarındaki değişiklikleri izlemek, kişiselleştirilmiş hizmetler sunmak, rakiplerinden farklılaşmak ve rekabet avantajı elde etmek için çalışmaktadır. Bu amaçla, RFM (Recency, Frequency, Monetary) analizi müşteri verilerini etkili bir şekilde sınıflandırmak için büyük bir öneme sahiptir. RFM, müşterinin ne kadar yakın zamanda alışveriş yaptığı ne sıklıkta alışveriş yaptığı ve ne kadar harcadığı gibi kriterlere dayanarak müşterileri segmentlere ayırır.

Geleneksel RFM yöntemi farklı yönlere genişletilerek daha ayrıntılı segmentasyonlar geliştirilmiştir. Bu genişletmeler, müşteri ilişkisinin uzunluğu (Length) ve ürün çeşitliliği (Variety) kriterleri eklenerek LRFM (Length, Recency, Frequency, Monetary) ve RFMV (Recency, Frequency, Monetary, Variety) yöntemleri ortaya çıkmıştır. Geleneksel olarak kabul edilen RFM yöntemi ile genişletilerek oluşturulan her bir yöntem kıyaslanacaktır. Çalışmada bu analizler biyoteknoloji sektörüne ait müşteri verileri üzerinden elde edilecektir. Analizler sonucunda müşterilere uygulanması gereken hangi pazar stratejilerinin daha etkili olabileceği ve sektör için hangi yöntemin daha etkili sonuç vereceğini göstermek hedeflemiştir. Yöntemlerin hepsini bir arada göstererek her bir yöntemin artı eksi yönleriyle firma için değerlendirebilmesi, planlayacağınız stratejilere daha kolay karar verilmesi, firmanın ne tür hizmetler sunması gerektiği, nasıl farklılaşabileceği gibi birçok konuda firmaya yanıtlar sunarak analiz sonuçlarının uygulanabilir planlar haline getirilmesi hedeflenmiştir.

Anahtar Kelimeler: (RFM, RFMV, LRFM, müşteri ilişkileri yönetimi, segmentasyon)

ABSTRACT

AN APPLICATION IN THE BIOTECHNOLOGY SECTOR ON THE COMPARISON OF MARKETING SEGMENTATION MODELS

In the contemporary business landscape, intensifying competition necessitates companies to exert more effort in enhancing customer loyalty. Many firms invest significantly in Customer Relationship Management (CRM) applications to monitor changes in customer needs, provide personalized services, differentiate themselves from competitors, and gain a competitive advantage. In this regard, Recency, Frequency, Monetary (RFM) analysis holds paramount importance in effectively classifying customer data. RFM segments customers based on criteria such as how recently they made a purchase, how frequently they make purchases, and how much they spend.

The traditional RFM method has been expanded in various directions to develop more detailed segmentation. These extensions include adding criteria such as the length of the customer relationship (Length) and product variety (Variety), giving rise to methods like LRFM (Length, Recency, Frequency, Monetary) and RFMV (Recency, Frequency, Monetary, Variety). Each method, whether traditional RFM or its extended counterparts, will be compared in this study. The analysis will be conducted using customer data from the biotechnology sector. The aim is to determine which market strategies may be more effective for applying to customers and which method yields more effective results for the industry.

By presenting and evaluating each method together, the analysis seeks to provide insights for the company to make informed decisions on strategies. This includes assessing the strengths and weaknesses of each method, facilitating easier decision-making for planned strategies, guiding the company on the types of services it should offer, and identifying avenues for differentiation. The ultimate goal is to transform the analysis results into actionable plans that can guide the company in various aspects, such as determining the most effective marketing strategies and services to offer in the biotechnology sector.

Key Words: (RFM, RFMV, LRFM, customer relationship management, segmentation)

ÖNSÖZ

Çok değerli hocam Prof. Dr. Hakan YILDIRIM'a, eğitim hayatımın her aşamasında sağladığı değerli emek, destek ve deneyimleri için, danışmanım ve yol gösterici hocam Doç. Dr. Mehmet Nuri İNEL'e tez sürecimdeki yardımları için, tez sürecimdeki zorlu aşamalarda hiçbir zaman desteğini esirgemeyen hocam Prof. Dr. Murat ÇİNKO'ya ve her konuda bilgisiyle yanımda olan Doç. Dr. Serkan Eti'ye ve anabilim dalımdaki hocalarıma içten teşekkürlerimi sunarım.

Tez sürecimde beni hiçbir zaman yalnız bırakmayan ailem, arkadaşlarım ve özellikle her konuda güçlü destekçim olduğunu hissettiğim anneme teşekkür ederim. Bu süreçte sağladıkları moral ve motivasyon benim için çok değerlidir.

Ebru SARIOĞLU

İSTANBUL, 2024

İÇİNDEKİLER

ÖZET ..... *i*

ABSTRACT ..... *ii*

ÖNSÖZ ..... *iii*

İÇİNDEKİLER ..... *iv*

TABLO LİSTESİ ..... *vi*

ŞEKİL LİSTESİ ..... *vii*

KISALTMALAR ..... *viii*

1. GİRİŞ *1*

2. KAVRAMSAL ÇERÇEVE *3*

2.1 Müşteri İlişkileri Yönetimi **3**

2.1.1 Müşteri İlişkileri Yönetimi'nin Tanımı 3

2.1.2 Müşteri İlişkileri Yönetimi'nin Önemi 4

2.1.3 Müşteri İlişkileri Yönetimi Süreci 5

2.2 Müşteri İlişkileri Yönetimi Bağlamında Veri Madenciliği Modelleri **6**

2.2.1 Veri Madenciliği Kavramı 6

2.2.2 Veri Madenciliği İşlevleri 7

2.2.2.1 Sınıflandırma 7

2.2.2.2 Kümeleme Analizi 8

2.2.2.3 Birliktelik Kuralı 11

2.3 Müşteri İlişkileri Yönetiminde Pazar Segmentasyonları **11**

2.3.1 Pazar Segmentasyon Kavramı 12

2.3.2 Pazar Segmentasyonunda Kullanılan Yöntemler 13

2.3.2.1 RFM (Recency-Frequency-Monetary) Analizi 13

2.3.2.2 RFMV (Recency-Frequency-Monetary-Variety) Analizi 15

2.3.2.3 LRFM (Lengh-Recency-Frequency-Monetary) Analizi 16

3. PAZAR SEGMENTASYONUNDA KULLANILAN YÖTEMLERİN LİTERATÜR TARAMASI *17*

4. UYGULAMA *26*

4.1 Uygulamanın Konusu **26**

4.2 Uygulamanın Amacı **26**

4.3 Uygulamanın Önemi **26**

4.4 Modellerin Uygulanması **27**

4.4.1 RFM (Recency-Frequency-Monetary) Analizi 28

4.4.2 RFMV (Recency-Frequency-Monetary-Variety) Analizi 41

4.4.2.1 LRFM (Lengh-Recency-Frequency-Monetary) Analizi 47

4.5 Uygulama Modellerinin Karşılaştırılması **52**

4.5.1 RFM Analizi ve RFMV Analizinin Kıyaslanması 52

4.5.2 RFM Analizi ve LRFM Analizinin Kıyaslanması 54

4.5.3 RFM, LRFM ve RFMV Analizlerinin Kıyaslanması 57

5. SONUÇ VE ÖNERİLER.....61

KAYNAKÇA.....65

TABLO LİSTESİ

Tablo 3-1: *Literatür taraması.* *22*

Tablo 4-1: *Dönüşüm Tablosu* *29*

Tablo 4-2: *CRM Veri Seti* *29*

Tablo 4-3: *Dönüşüm Veri Seti* *29*

Tablo 4-4: *RFM Skor Tablosu* *30*

Tablo 4-5: *RFM Skor Tablosu2* *31*

Tablo 4-6*: RFM Segment Haritası* *33*

Tablo 4-7*: RFM Değerlerine göre Etiketlenmiş Müşteri Segmentleri* *35*

Tablo 4-8*: RFM Analizi Tanımlayıcı İstatistikleri* *35*

Tablo 4-9*: Segment Dağılımı* *36*

Tablo 4-10: *RFM Skor Kümeleri* *38*

Tablo 4-11 *Müşteri Profilleri* *39*

Tablo 4-12: *RFMV Modelindeki Değişken Tanımları* *41*

Tablo 4-13*: RFMV Modelindeki İstatistikler* *41*

Tablo 4-14 *Ortlama RFMV Değerleri* *43*

Tablo 4-15: *RFMV Kümeleri* *44*

Tablo 4-16: *RFMV Küme Ortalamaları* *45*

Tablo 4-17 *LRFM Modelineki Değişken Tanımları* *47*

Tablo 4-18: *LRFM Modelindeki İstatistikler* *47*

Tablo 4-19*: LRFM Skor Kümeleri* *49*

Tablo 4-20: *RFM-RFMV Küme Karşılaştırması* *52*

Tablo 4-21: *RFM-RFMV Kıyaslama* *53*

Tablo 4-22: *RFM-LRFM Küme Karşılaştırılması* *54*

Tablo 4-23: *RFM-LRFM Kıyaslama* *56*

Tablo 4-24: *LRFM-RFMV Kıyaslama* *56*

Tablo 4-25: *Modellerin Karşılaştırılması* *57*

Tablo 4-26: *Model Değerlendirilmesi* *59*

ŞEKİL LİSTESİ

***Şekil 4-1**: Müşteri Veri Seti Örneği* *27*

***Şekil 4-2:** Segment haritası* *32*

***Şekil 4-3**: Müşteri Segment Haritası* *34*

***Şekil 4-4:** RFM Küme Grafiği* *37*

***Şekil 4-5**: RFMV Küme Grafiği* *42*

***Şekil 4-6:** Müşteri Değer Matrisi ve Müşteri Ürün Derinlik Matrisi* *43*

***Şekil 4-7:** LRFM Küme Grafiği* *48*

***Şekil 4-8:** Müşteri Sadakat Matrisi* *48*

KISALTMALAR

CLV – Müşteri Yaşam Boyu Değeri

CRM – Müşteri İlişkileri Yönetimi

LRFM – Güncellik, Sıklık, Parasallık ve İlişki Uzunluğu Modeli

RFM – Güncellik, Sıklık ve Parasallık Modeli

RFMV – Güncellik, Sıklık, Parasallık ve Çeşitlilik Modeli

L – Length (uzunluk)

R – Recency (Güncellik)

F – Frequency (Sıklık)

M – Monatary (Parasal)

V– Variety (Çeşitlilik)

1. GİRİŞ

Günümüzde, insanların bir ürün veya hizmete ulaşmaları ve bu konuda bilgi sahibi olmaları teknoloji ile oldukça kolaylaşmıştır. Müşteriler, satın almak istedikleri ürünler için alternatifleri araştırabilir, farklı markalara yönelebilir ve fiyat performans değerlendirmeleri yapabilmektedirler. Bu bilgiye kolayca ulaşılabilen bir dünyada rekabet edebilmek, sürdürülebilirliği sağlamak ve müşteri sadakatini elde tutabilmek, müşterilerimizin kim olduğunu tanımaktan, müşteri kitlesini anlamlandırmaktan geçmektedir. Bu bağlamda, müşterilerimizi tanımlamak için kimdir, kimlere satış yapıyoruz, kimlere neden satış yapamıyoruz gibi sorular ortaya çıkmaktadır.

Bu çalışmada, firmaların söz konusu sorulara cevap verebilmesi için geliştirilmiş analizler arasından geleneksel bir yöntem olan, MİY verilerinden elde edilen RFM analizi kullanılmaktadır. Müşterilerimizin kim olduğu, en son ne zaman alışveriş yaptığı ve yaptığı alışveriş tutarı gibi kriterleri analiz ederek, müşterilere uygulanması gereken stratejilere karar verebilmektedir. Çalışmada sadece geleneksel yöntemle sınırlı kalınmamış, analize V ve L parametreleri eklenerek RFMV ve LRFM analizleri uygulanmıştır. Bu ek parametrelerin kullanılmasıyla, müşterilerin bulunduğu kümeler arasında farklılıklar ortaya çıkıp çıkmadığı, müşterilerin konumlandırılmasında hangi parametrelerin neden önemli olduğu ve seçilen sektöre göre hangi analizin daha etkili olduğu gibi sorulara yanıt verilmektedir.

Müşteri verileri RFM analiziyle değerlendirilecek sonrasında kendi içerisinde karşılaştırılacaktır. Elde edilen müşteri gruplarının kümeleme analizi ile benzerlik ve farklılık dereceleri ele alınacaktır. Elde edilen sonuçlar, uygulanan firmanın kullanması gereken analiz yöntemini belirlemede kritik bir rol oynayacak ve firmanın pazarlama stratejilerini daha net bir şekilde belirlenecektir. Müşterileri üç farklı analiz yöntemiyle değerlendirmek, sektörde hangi müşteri gruplarının hangi kriterlere göre değerlendirilmesi gerektiği konusunda rehberlik edecektir. Bu sonuçlar, firmanın pazarlama stratejilerini optimize etme ve müşteri ilişkilerini güçlendirme konusunda önemli bir yol haritası sunacaktır.

Çalışmanın biyoteknoloji sektörünü ele almasının temel nedenleri arasında, son yıllarda yaşanan pandemi olaylarıyla birlikte bu sektöre olan talebin artması, hastalıklara yönelik araştırmalardaki artış ve gelecekte bu sektöre duyulan ihtiyacın daha da yükselmesi bulunmaktadır. Ayrıca, literatürde biyoteknoloji sektörüne ait RFM, RFMV ve LRFM analizlerini içeren bir çalışmanın bulunmaması da yer almaktadır.

Bu çalışma, söz konusu literatür boşluğunu doldurmayı hedeflemektedir. Bu boşluğun doldurulması, işletmelerde sıkça kullanılan RFM analizine ek olarak RFMV ve LRFM analizinin de biyoteknoloji sektöründe uygulanabilir olduğunu göstermesi açısından önemlidir.

Çalışma beş bölümden oluşmaktadır. İlk olarak Giriş bölümüne yer verilecek sonrasında ikinci bölümde Kavramsal Çerçeve ile tanımlar yapılarak konular hakkında bir zemin oluşturulacaktır. Üçüncü bölümde Pazar Segmentasyonunda Kullanılan Yöntemlerin Literatür Taraması ile yapılmış olan çalışmalar ele alınacak, dördüncü bölümde Uygulama yer alırken son bölümde ise Sonuç ve Öneriler bölümü yer almaktadır.

2. KAVRAMSAL ÇERÇEVE

2.1 Müşteri İlişkileri Yönetimi

Bu bölümde, müşteri ilişkileri yönetimi kavramı tanımlanmakta ve bu kavramın önemi vurgulanmaktadır. Müşteri ilişkileri yönetimi süreci ayrıca; müşterilerin belirlenmesi, müşterilerle ilişkilerin kurulması ve müşterilerle ilişkilerin korunması ve geliştirilmesi aşamalarında detaylı bir şekilde açıklanmaktadır.

2.1.1 Müşteri İlişkileri Yönetimi'nin Tanımı

Müşteri ilişkileri, bir işletme ile müşteri arasında gerçekleşen satış öncesi, satış anı ve sonrasındaki tüm faaliyetleri ve işlemleri kapsayan bir süreçtir (Odabaşı, 2004). Müşteri ilişkileri yönetimi terimi, farklı kaynaklarda farklı şekillerde tanımlanmaktadır. Couldwell'un ifadesine göre, müşteri ilişkileri yönetimi, mevcut müşteri bilgilerinin etkin bir şekilde kullanılmasıyla işletmenin karlılığını artırmasına ve müşteri hizmetlerini geliştirmesine olanak tanıyan bir uygulama olarak tanımlanabilir (Couldwell, 1999). Ayrıca, Peppers, Rogers ve Dorf benzer bir tanımına göre, müşteri ilişkileri yönetimi (MİY), müşterinin ifadeleri ve müşteriye ait diğer bilgileri kullanarak birebir pazarlama ve ilişkisel pazarlama stratejilerinin uygulanmasıdır. Swift (2001) müşterilere dair veri toplama, müşteri özelliklerini anlama ve bu özellikleri belirli pazarlama faaliyetlerinde kullanma sürecini tasarlamış bir yaklaşım olarak ele almıştır. Buttle ve Maklan ise müşteri ilişkileri yönetimini stratejik bir perspektiften ele alarak, stratejik olarak önemli müşterilerle uzun vadeli ve karşılıklı faydalara dayanan ilişkilerin geliştirilmesi ve yönetilmesi olarak tanımlamaktadır.

Kumar & Reinartz (2006) ise literatürdeki farklı tanımlardan yola çıkarak müşteri ilişkileri yönetimini stratejik müşteri ilişkileri yönetimi, operasyonel müşteri ilişkileri yönetimi ve analitik müşteri ilişkileri yönetimi olarak 3 grupta tanımlamaktadır. Söz konusu 3 grup MİY tanımı şu şekilde açıklanabilir.

1- *Stratejik Müşteri İlişkileri Yönetimi:* Stratejisinin temel amacı, stratejik olarak önemli müşterileri elde tutmak ve bunu başarmak için müşteri elde tutma hedefi belirlemektir. Bu hedefin gerçekleştirilmesi, müşteri beklentilerini aşan değer tekliflerinin geliştirilmesi, iletişim kurulması ve sunulması üzerine odaklanır. Değer teklifi, müşterilerin bir şirketle ilişkileri sırasında deneyimledikleri ürün, hizmet, süreç, fiyat, iletişim ve etkileşim gibi çeşitli unsurları içerir. Değer teklifi, bir şirketi diğerlerinden ayıran ve müşteri odaklılığına özgü kılan temel bir unsurdur.
2- *Operasyonel Müşteri İlişkileri Yönetimi*: Bu yaklaşım, günlük iş süreçlerine odaklanır ve müşteri ilişkilerini yönetme süreçlerini içerir. Müşteri hizmetleri, satış yönetimi ve pazarlama gibi operasyonel faaliyetler, müşteri memnuniyetini artırmak ve müşteri ilişkilerini güçlendirmek için etkileşimde bulunur. Bu, müşteriye daha iyi hizmet vermek ve operasyonel verimliliği artırmak için tasarlanmıştır.

3- *Analitik Müşteri İlişkileri Yönetimi:* Müşteri verilerini analiz etmeye odaklanır. Veri madenciliği, analitik araçlar ve raporlama gibi teknikler kullanılarak müşteri davranışları, tercihleri ve eğilimleri hakkında derinlemesine anlayış elde etmeye yöneliktir. Bu bilgiler, stratejik ve operasyonel karar alma süreçlerinde kullanılır ve müşteriye özel çözümler geliştirmek için kullanılır.

Müşteri ilişkileri yönetimi, çeşitli bakış açılarını birleştirerek müşteri odaklı, stratejik bir yaklaşım sunar. Müşteri memnuniyeti, sadakati, rekabet avantajı ve işletme verimliliği gibi unsurları içine alan bu süreç, işletmelerin sürdürülebilir başarıya ulaşmalarına katkı sağlar.

2.1.2 Müşteri İlişkileri Yönetimi'nin Önemi

Müşteri ilişkileri yönetimi, 1990'lı yıllardan itibaren literatürde daha fazla ilgi görmekte ve günümüzde iş dünyasında önemli bir strateji olarak kabul edilmektedir (Payne ve Frow, 2005). Başlangıçta sadece satış fonksiyonuyla sınırlı olan bu yaklaşım, zaman içinde işletmeler için rekabet avantajı sağlayabilecek kapsamlı bir stratejiye dönüşmüştür (Kumar ve Reinartz, 2018). Müşteri ilişkileri yönetimi her zaman işletmeler için kritik bir stratejidir. Bu yaklaşım, müşteri sadakatini artırarak tekrarlayan iş sağlar, müşteri memnuniyetini güçlendirir ve rekabet avantajı sağlar. Müşteri geri bildirimi toplama ve analiz etme, maliyet verimliliği sağlama ve marka imajını güçlendirme gibi avantajlarıyla MİY, işletmelerin uzun vadeli başarılarına katkıda bulunur.

İlişkisel pazarlama, müşteri ilişkileri yönetiminin temel prensiplerini oluşturur ve bu yaklaşım, uzun vadeli alıcı-satıcı ilişkilerini kurmayı ve sürdürmeyi hedefler (Reinartz ve Kumar, 2003). Müşteri ilişkileri yönetimi, pazarlama stratejilerini markayı ön planda tutan yaklaşımdan müşteriyi ön planda tutan yaklaşıma kaydırmıştır (Mithas, Krishnan ve Fornell, 2005). Bu strateji, bir işletmedeki bilgi teknolojileri, insan kaynakları, müşteri hizmetleri, pazarlama, satış ve muhasebe gibi tüm departmanları etkileyerek her kanalın gücünü arttırır (Chen ve Popovich, 2003). Ayrıca, müşteri ilişkileri yönetimi gelir artırıcı etkisiyle birlikte rekabet avantajı sağlayan bir faktör olarak da kabul edilir (Yurdakul, 2003).

Müşteri ilişkileri yönetimi, müşterilerle ilgili bilgilerin analizi yoluyla işletmelerin müşteri ihtiyaçlarını ve beklentilerini daha iyi anlamalarını sağlar; bu da işletmelerin daha etkili bir pazarlama stratejisi oluşturmalarına olanak tanır (Davenport, Harris ve Kohli, 2000; Nambisan, 2002).

Reichheld (1996), müşteri sadakatinin artırılmasıyla küçük geliştirmelerin bile kârlılıkta önemli artışlar sağlayabileceğini savunmaktadır. Bu nedenle, müşteri ilişkileri yönetimi, işletmelerin müşteri elde tutma stratejilerini geliştirerek uzun vadeli başarılar elde etmelerine olanak tanır.

(Selvi, 2007) belirttiği üzere, müşteri ilişkileri yönetiminin işletmeye sağlayabileceği faydalar şu şekilde özetlenebilir:

- Daha kârlı müşterilerin sadakatini sağlamak,
- Pazarlama faaliyet maliyetlerini azaltmak,
- Çapraz/yukarı satış fırsatlarını artırmak,
- Kaybedilen müşteri oranını azaltmak,
- Hedef kitle ile uyumlu ürün-hizmet, fiyat ve satış kanalını belirlemektir.

MİY, işletmeler için giderek daha önemli hale gelen bir yaklaşımdır. MİY'nin gelecekte daha da yaygınlaşması ve işletmeler için daha da önemli bir araç haline gelmesi beklenmektedir. Sonuç olarak, müşteri ilişkileri yönetimi, işletmelerin müşterileriyle olan etkileşimini sistemli bir şekilde yönetmelerine ve güçlendirmelerine yardımcı olan stratejik bir süreçtir. Bu süreç, müşteri memnuniyeti, sadakati, rekabet avantajı ve uzun vadeli başarı için kritik bir rol oynar.

2.1.3 Müşteri İlişkileri Yönetimi Süreci

Müşteri İlişkileri Yönetimi (MİY), işletmelerin müşterilerle kurduğu ilişkilerin etkin bir şekilde yönetilmesini amaçlayan kritik bir stratejidir. Müşteri kavramının temelinde, bir işletmenin ürün veya hizmetlerini satın almış veya potansiyel satın alma kapasitesine sahip bireyler bulunmaktadır (Arslan, 2014)

MİY'nin odaklandığı alanlar arasında müşteri kazanma, müşterilerle ilişkiler kurma ve bu ilişkileri uzun süreli hale getirme yer almaktadır. Bu strateji, işletmeye daha fazla kâr sağlayan müşterilerle güçlü bağlar kurmayı ve müşterilerin işletmeyi tercih etmelerini sağlayacak etkili yöntemleri bulmayı amaçlar.

Müşteri ilişkileri yönetimi süreci, daha kârlı müşterilerin belirlenmesiyle başlar ve bu müşterilerle kurulan ilişkilerin geliştirilmesini hedefler. Bu süreç Bloemer vd. (2003) tarafından şu aşamalara ayrılır:

1. Müşterilerin Belirlenmesi: İşletme, potansiyel müşterileri analiz ederek daha fazla kâr sağlayabilecek müşteri segmentlerini belirler.
2. Müşterilerle İlişkilerin Kurulması: Belirlenen müşteri segmentleriyle etkili iletişim stratejileri kullanılarak ilişkiler kurulur. Müşteri beklentileri anlaşılır ve özel ihtiyaçlar dikkate alınır.
3. Müşterilerle İlişkilerin Korunması ve Geliştirilmesi: Kurulan ilişkiler sürdürülerek müşteri sadakati artırılır. Müşteri memnuniyeti sağlanır ve sürekli olarak müşteri ihtiyaçları göz önünde bulundurularak ilişkiler geliştirilir.

Bu süreç, işletmelerin müşteri odaklı bir yaklaşım benimsemelerini ve müşteri ilişkilerini stratejik bir şekilde yönetmelerini sağlar.

2.2 Müşteri İlişkileri Yönetimi Bağlamında Veri Madenciliği Modelleri

Çalışmanın bu bölümde, müşteri ilişkilerini anlamak, müşteri davranışlarını öngörmek ve pazarlama stratejilerini optimize etmek amacıyla kullanılan veri madenciliği yöntemleri ve modelleri ele alınacaktır.

2.2.1 Veri Madenciliği Kavramı

Veri bilimciler, veri madenciliği teknikleri üzerine çalışmaya 1950'li yıllarda başlamışlardır. Bu dönemde, mantık ve bilgisayar bilimleri alanlarında yapay zekâ (artificial intelligence) ve makine öğrenme (machine learning) konuları geliştirilmiştir. 1960'lı yıllarda ise istatistikçiler, regresyon analizi, en büyük olabilirlik kestirim (maximum likelihood estimates), sinir ağları gibi yeni algoritmalar üzerinde çalışmışlardır. Bu yöntemler, veri madenciliğinin temel adımlarını oluşturmuştur. Ayrıca, veritabanı sistemleri bu dönemde giderek gelişmiş ve büyük sayıda metin dokümanlarının saklanması ve bilginin geri kazanılması konusunda önemli ilerlemeler kaydedilmiştir. Bu gelişmeler, veri madenciliği süreçlerini desteklemek amacıyla veritabanı sistemlerinin daha etkili ve verimli hale gelmesine katkı sağlamıştır. (Can vd. 2012)

Miehael ve Linoff'un tanıma göre, veri madenciliği; büyük miktardaki veriyi analiz ederek bu veriden anlamlı ve yorumlanabilir modeller ile kurallar çıkarmayı amaçlar (Miehael & Linoff., 1997).

Veri madenciliği, verileri analiz ederek ve araştırarak içerdikleri olası yararlı bilgileri ortaya çıkarma sürecidir (Michael J Shaw, Tan, & Welge, 2001). Bu süreç, verilerin içinde gizlenmiş olan kalıpları ve ilişkileri keşfetmeyi amaçlar (Rygielski, Wang, & Yen, 2002)

Veri madenciliği, büyük veri yığınlarından oluşan veritabanı sistemlerinde bulunan gizli bilgilerin çekilmesini sağlayan bir süreçtir. Bu işlem, istatistik, matematik disiplinleri, modelleme teknikleri, veritabanı teknolojisi ve çeşitli bilgisayar programları (r,pyhton,weka) kullanılarak gerçekleştirilir.

Veri madenciliği, büyük miktarda veriyi inceleme amacıyla kurulduğu için veritabanlarıyla sıkı bir ilişkiye sahiptir. Bu süreçte, gerekli verinin hızla ulaşılabilir olması için verilerin amaca uygun bir şekilde saklanması ve gerektiğinde hızla ulaşılabilmesi büyük önem taşır. Günümüzde yaygın olarak kullanılan veri ambarları, günlük kullanılan veritabanlarının birleştirilmiş ve işlemeye daha uygun bir özetini saklamayı amaçlar. Bu şekilde, veri madenciliği için gerekli olan verilere daha hızlı ve etkili bir şekilde erişim sağlanabilir, analiz süreçleri optimize edilebilir (Baykal, 2006).

Veri madenciliği verinin yoğun olarak üretildiği ve bunun sonucu olarak veritabanlarının oluştuğu hemen her ortamda uygulama kullanım alanı bulabilir. Bazı uygulama alanları başlıklar halinde aşağıdaki gibidir: (Can vd. 2012)

- Veri tabanı analizi ve karar verme desteği
- Pazar Araştırması
- Risk Analizi
- Belgeler arası benzerlik: haber kümeleri, e-posta Müşteri kredi risk araştırmaları
- Kurum kaynaklarının en optimal biçimde kullanımı
- Geçmiş ve mevcut yapı analiz edilerek geleceğe yönelik tahminlerde bulunma
- Bilimsel ve mühendislik alanında
- Sağlık alanında
- Ticaret alanında
- Alışveriş alanında
- Bankacılık ve finans alanında
- Eğitim sektöründe
- Internet (Web) kullanımında
- Doküman kullanımında
- Sigortacılık
- Pazarlama

Karmaşık yeteneklerinin bir sonucu olarak, başarılı bir veri madenciliği uygulaması için iki öncül önemlidir: çözülecek problemin net bir şekilde formüle edilmesi ve ilgili çözüme erişim (Pegarkov, 2006).

Sonuç olarak veri madenciliği, veri toplamak ve yönetmekten daha fazlasını kapsar, aynı zamanda analiz ve tahminleri de içerir. Veri madenciliği, büyük veri setlerinden değerli bilgilerin çıkarılmasını sağlayan kritik bir süreçtir. İşletmelere rekabet avantajı, karar alma süreçlerinde rehberlik, müşteri ihtiyaçlarını anlama ve hızlı adaptasyon gibi birçok alanda önemli faydalar sağlar.

2.2.2 Veri Madenciliği İşlevleri

Veri madenciliği, büyük veri kümelerinden anlamlı bilgiler çıkarmak için kullanılan bir süreçtir. Veri madenciliği işlevleri, bu sürecin farklı aşamalarında kullanılan özel görev ve teknikleri ifade eder. Bu bölümde veri madenciliği işlevlerinin bazılarına değinilecektir.

2.2.2.1 Sınıflandırma

Sınıflandırma, veri madenciliğinde en yaygın kullanılan alanlardan biridir. Bu yöntem, var olan bir veri tabanının bir bölümü eğitim olarak kullanılarak sınıflandırma kurallarının oluşturulmasını içerir. Bu kurallar, yeni bir durum ortaya çıktığında nasıl karar verileceğini belirlemede yardımcı olur.

Veri madenciliğinde sınıflandırma grubu içinde en sık kullanılan tekniklerden biri karar ağaçlarıdır. Aynı zamanda lojistik regresyon, diskriminant analizi, sinir ağları ve bulanık kümeleme gibi diğer teknikler de yaygın olarak kullanılmaktadır. İnsanlar genellikle verileri sınıflandırır, kategorize eder ve derecelendirir. Bu nedenle sınıflandırma, veri madenciliğinin temel bir bileşeni olarak ve veri hazırlama aracı olarak işlev görür. (Coşlu, 2013)

Sınıflandırma, bir veri kümesindeki her öğeyi önceden belirlenmiş bir dizi sınıfa veya gruba ayırmak için kullanılır. Veri analizi görevi olan sınıflandırma, kategorik etiketleri (sınıf etiket öznitelikleri) tahmin etmek üzere bir model veya sınıflandırıcı inşa edilen bir alandır. Sınıflandırma, bir veri koleksiyonundaki öğeleri hedef kategorilere veya sınıflara atayan bir veri madenciliği işlevidir. Sınıflandırmanın hedefi, verideki her durum için hedef sınıfı doğru bir şekilde tahmin etmektir (G.Kesavaraj & S.Sukumaran, 2013).

Müşteri sınıflandırma, müşterilerin belirlenen segmentler arasında en yakın olanla ilişkilendirilmesini içerir. Müşterilerin sınıflandırılması, demografik bilgiler veya davranışsal modeller gibi faktörlere dayalı olarak gerçekleştirilebilir. Bu bağlamda, müşteri davranışlarının anlaşılmasında çeşitli sayısal analizler ve veri madenciliği yöntemleri kullanılır.

Sınıflandırmanın birçok uygulaması müşteri segmentasyonunda, iş modellemede, pazarlamada, kredi analizinde ve biyomedikal ile ilaç tepki modellemesinde yaygın olarak kullanılmaktadır (G.Kesavaraj & S.Sukumaran, 2013). Bu uygulamalar, veri madenciliğinin çeşitli alanlarında doğru ve etkili kararlar almak için sınıflandırma tekniklerini kullanmanın önemini vurgular.

Baesens vd, (2003) müşterilerin gelecekteki yaşam döngüsünü öngörmeye yönelik Bayesçi ağları kullanarak bir sınıflama modeli sunmuşlardır. Bu modelde, müşteriler başlangıçta sergiledikleri satın alma davranışlarına göre kısa vadeli veya uzun vadeli müşteriler olarak iki sınıfa ayrılır. Ayrıca, müşteri yaşam boyu değeri, sınıflandırma için önemli bir ölçüt olarak kabul edilir.

2.2.2.2 Kümeleme Analizi

Kümeleme analizi, araştırmada incelenen unsurları benzerliklerine göre gruplara ayırarak sınıflandırmayı sağlayan bir yöntemdir. Temel amaç, anlamlı ve doğal sınıflar oluşturmaktır. Bu nedenle oluşturulan kümeler, incelenen nesnelerin özgün yapısını yansıtmalıdır. Ancak bazı durumlarda, veriyi özetleme gibi farklı amaçlar için de kümeleme analizi kullanılabilir. Bu teknik, psikoloji, sosyal bilimler, biyoloji, istatistik, veri madenciliği, örüntü tanıma gibi birçok alanda önemli bir rol oynar.

Kümeleme, birçok alanda, makine öğrenimi, veri madenciliği, desen tanıma, görüntü analizi dahil olmak üzere istatistiksel veri analizi için yaygın olarak kullanılan bir tekniktir. Bu yöntem, benzer özelliklere sahip nesneleri farklı gruplara ayırmayı veya daha kesin bir ifadeyle bir veri kümesini belirli bir uzaklık ölçüsüne göre alt kümelerine bölmeyi içerir. (Madhulatha,2012)

Kümeleme Analizi, grup sayısı önceden bilinmeyen ve sınıflandırılmamış verileri benzerliklerine göre sınıflandırmak için kullanılır. Önceden belirlenmiş bir sınıflandırma olmaması, kümeleme analizini denetimsiz öğrenme kategorisine sokar. Eğer sınıflar önceden biliniyorsa, bu durumda sınıflandırma analizi kullanılır ve burada öğrenme süreci denetimli hale gelir. Çünkü sınıflar önceden bilinmektedir.

Kümeleme, nesneler arasındaki ilişki ve benzerlikleri ortaya çıkararak veri setindeki unsurları farklı kümelerde gruplandırır. Bu, verilerin birbirlerine olan benzerlikleri temel alarak hangi gruplara ve kaç farklı gruba ayrılacağını belirler. Her bir oluşturulan gruba bir küme ismi atanır.

Bugün hala pek çok alanda kullanılan bu analiz yöntemi, bilim dünyasında ve iş dünyasında veri analizi ve sınıflandırmada önemli bir rol oynamaya devam etmektedir.

K-Ortalamalı Kümeleme Analizi

K-Ortalamalı kümeleme, 1967 yılında J.B. MacQueen tarafından geliştirilmiş ve en basit, yaygın ve denetimsiz öğrenme tekniklerinden biri olarak kabul edilmiştir. Bu algoritma, hata kare kriterini kullanarak çalışır ve her veriyi sadece bir kümeye atar, bu da onu kesin bir kümeleme tekniği yapar. Temel prensip, her kümenin merkez noktasının kümeyi temsil etmesidir ve genellikle eşit büyüklükte küresel kümeleri bulmaya eğilimlidir (MacQueen, 1967). MacQueen için k-ortalama kümeleme yöntemi "benzerlik gruplama" veya "kümeleme" sorununa uygulanmasının en belirgin kullanımını ele almaktadır. Amaç, benzersiz ve kesin bir gruplama bulmak değil, büyük miktarda N-boyutlu veriyi araştırmacıya makul derecede iyi benzerlik grupları sağlayarak anlamlandırmaktır.

K-Ortalamalı kümeleme algoritması, hata kare fonksiyonunu kullanan bir algoritma olup, bu fonksiyon bölümlemeli kümeleme tekniklerinde en sık kullanılan kriter fonksiyonlarından biridir. SSE (Sum of Squared Errors) olarak ifade edilen bu kriter fonksiyonu, nesnelerin küme merkezlerine olan uzaklıklarının karelerinin toplamını gösterir. Kümeleme sonucunda elde edilen en iyi sonuç, en düşük SSE değerine sahip olan kümelemedir. SSE değeri düşük olduğunda, nesneler küme merkezlerine yakın konumlanmış demektir.

K-ortalamalı kümeleme algoritması, her bir kümenin merkezinin kümedeki nesnelerin ortalama değeri ile temsil edildiği bölümleme için kullanılır. (Han, Kamber, & Pei, 2012)

k: küme sayısı,

D: n nesne içeren bir veri kümesi.

Çıkış: k kümes kümesi.

K-ortamalı kümelerin algoritması aşağıda verilmiştir; (Han, Kamber, & Pei, 2012)

Yöntem:

1- k nesneyi D'den başlangıç küme merkezleri olarak keyfi olarak seç; tekrarla

2- her nesneyi, nesnenin kümedeki nesnelerin ortalama değerine dayanarak en benzer olduğu kümeye yeniden atayın;

3- küme ortalamalarını güncelle, yani her küme için nesnelerin ortalama değerini hesaplayın;

4- değişiklik olana kadar tekrar et;

5- eğer belirgin bir değişiklikten bahsedilmiyorsa, tekrar sonlandırılır ve algoritma durdurulur.

K-Ortalamalı kümeleme algoritması, rastgele seçilen bir bölümleme ile başlar ve nesnelerin kümelere atanması, hata kriteri sağlanana kadar devam eder. Küme sayısını belirleyen k parametresi kullanıcı tarafından önceden belirlenir. Bu algoritmanın uygulama kolaylığı sağlaması, onu yaygın olarak kullanılan bir teknik haline getirir. Ancak, bazı zayıf yönleri de beraberinde getirmektedir. Örneğin, başlangıç değerlerinin kümeleme sonucunu önemli ölçüde etkilemesi, yerel minimumlar yaratma eğilimi, küme sayısının önceden belirlenmesi gerekliliği gibi zayıf yönler barındırır. Bu zayıf yönler, özellikle de büyük veri setleri üzerinde çalışırken ve aykırı değerlerin bulunduğu durumlarda algoritmanın verimliliğini etkileyebilir.

K-ortalama bölütleme yöntemiyle yapılan kümeleme işlemi şu şekildedir: 2- boyutlu uzayda konumlanmış nesneler kümesi üzerinde k = 3 için bir kümeleme yapılır. Başlangıçta, üç nesne rastgele seçilir ve bu nesneler küme merkezi olarak belirlenir (+ işareti ile gösterilir). Her nesne, en yakın küme merkezine göre bir kümeye atanır, bu da noktalı eğrilerle çevrili siluetleri oluşturur. Daha sonra, küme merkezleri güncellenir; her kümenin mevcut nesnelerine dayanarak ortalama değeri hesaplanır. Yeni küme merkezleri kullanılarak nesneler, en yakın küme merkezine göre kümelere yeniden dağıtılır ve bu, tireli eğrilerle çevrili yeni siluetleri oluşturur. Bu süreç tekrarlanır ve iteratif olarak yeniden yerleştirme süreci olarak adlandırılan bu işlem, herhangi bir kümedeki nesnelerin tekrar atanmamasıyla sona erer. Ortaya çıkan kümeler, kümeleme işlemi tarafından döndürülür. (Madhulatha, 2012)

K-ortalama yöntemi global optimuma ulaşma garantisi vermez ve genellikle yerel optimumda sonlanır. Sonuçlar, başlangıç küme merkezlerinin rastgele seçimine bağlıdır. İyi sonuçlar elde etmek için, k-ortalama algoritması genellikle farklı başlangıç küme merkezleriyle birkaç kez çalıştırılır. Yöntemin büyük veri setlerini işleme konusunda ölçeklenebilir ve verimli olduğu anlamına gelir. (Köroğlu & Kahraman, 2020)

K-ortalama yönteminin çeşitli varyantları bulunmaktadır ve bu varyantlar, başlangıç k-ortalamaların seçiminde, benzerlik hesaplamasında ve küme ortalamalarının belirlenmesinde farklı stratejilere dayanır. Yenilikçi yaklaşımlar, k-ortalama algoritmasının performansını artırmayı hedefler.

2.2.2.3 Birliktelik Kuralı

Veri madenciliği, bir veri tabanı içindeki kayıtlar arasındaki ilişkileri inceleyerek, hangi olayların eş zamanlı olarak birlikte gerçekleşebileceğini ortaya koymaya çalışan yöntemleri içerir. Bu teknikler, özellikle pazarlama alanında (pazar sepet analizleri) sıkça kullanılır. En yaygın uygulamalarından biri, perakende satışlarda müşterilerin satın alma eğilimlerini belirlemek amacıyla gerçekleştirilen birliktelik çözümlemeleridir. Bu uygulamalar, müşterilerin aynı anda satın aldığı tüm ürünleri ele alarak satın alma eğilimini ortaya koyar ve "pazar sepet çözümlemesi" olarak adlandırılır. (Coşlu, 2013)

Birliktelik analizi, belirli bir destek ve güven düzeyi eşiği belirlenerek sıkça tekrarlanan işlemlerin, kayıtların veya verilerin belirlenip incelenmesini ifade eder. Bu sayede, veri seti içindeki önemli ilişkiler, destek ve güven eşiği değerleri kullanılarak analiz edilerek belirlenebilir.

Birliktelik analizi genellikle market sepet analizi olarak bilinen bir uygulama alanına sahiptir. Örneğin, bir perakende mağazasının satış verilerini ele alınsın. Birliktelik analizi kullanılarak, müşterilerin hangi ürünleri bir arada satın aldıklarını ve bu ürünler arasındaki ilişkileri belirlenebilir. Bu bilgiler, mağaza sahiplerine önerilen ürünlerin yerleşimini optimize etme, kampanya stratejilerini geliştirme ve stok yönetimini iyileştirme konularında yardımcı olabilir.

Birliktelik analizi genellikle "destek" ve "güven" kriterleri üzerinden gerçekleştirilir: (Sabah & Bayraktar, 2020)

1- Destek (Support): Belirli bir kuralın veya öğe kombinasyonunun ne kadar sık görüldüğünü gösterir. Yüksek destek değeri, bu kuralın sıkça gerçekleştiği anlamına gelir.
2- 2-Güven (Confidence): İki öğe arasındaki ilişkinin ne kadar güvenilir olduğunu ifade eder. Yüksek güven değeri, bir öğenin satın alındığında diğerinin de büyük olasılıkla satın alındığı anlamına gelir.

Örneğin, "Ekmek alışveriş yapan müşterilerin %75'i süt de satın alıyor" şeklinde bir kural, yüksek bir destek ve güven değerine sahip bir birliktelik kuralını temsil edebilir. Birliktelik analizi, veri setlerindeki desenleri keşfetmek ve iş stratejilerini optimize etmek için kullanılan güçlü bir araçtır.

2.3 Müşteri İlişkileri Yönetiminde Pazar Segmentasyonları

Müşteri İlişkileri Yönetimi (MİY) kapsamında, pazar segmentasyonları önemli bir stratejik araçtır. Pazar segmentasyonu, geniş bir pazarı daha küçük, daha yönetilebilir ve daha özel hedef kitlelere bölmeyi içerir. Bu, farklı müşteri gruplarına özelleştirilmiş pazarlama stratejileri uygulayarak müşteri memnuniyetini artırmayı, müşteri sadakatini geliştirmeyi ve genel olarak şirketin rekabet avantajını güçlendirmeyi amaçlar. Çalışmanın bu bölümünde kullanılan pazar segmentasyonu kavramı ve modellerine değinilecektir.

2.3.1 Pazar Segmentasyon Kavramı

Pazar segmentasyonu, işletmelerin karmaşık pazarlarda başarılı olmalarına yardımcı olan kritik bir stratejidir. Müşteri tabanını anlamak ve ihtiyaçlarına odaklanmak, uzun vadeli müşteri sadakati ve şirket başarısı için temel bir adımdır. Bu nedenle, pazarlamacılar ve iş liderleri, pazar segmentasyonunu kapsamlı bir strateji olarak benimsemeli ve bu yöntemi kullanarak müşteri tabanlarını etkili bir şekilde yönetmelidirler.

Pazarı segmente etmenin tek doğru yolu yoktur. Sıkça, birkaç segmentasyon, Kotler'ın kriterlerini karşılayabilir. O, pazar segmentasyon değişkenlerini genellikle dört ana alana bölmektedir. Bu dört alan coğrafi, demografik, psikografik ve davranışsaldır (Kotler, 1980).

Coğrafi segmentasyon, anlaşılması en basit konulardan biridir. Bir pazar coğrafi olarak segmente edildiğinde, tüketicinin ihtiyaçları veya bu ihtiyaçları karşılama yöntemleri coğrafi olarak değişiklik gösterir. Bu durum, bir ülkenin bölgesine, nüfus yoğunluğuna veya iklimine göre farklılık gösterebilir. (Kotler, 1980).

Demografik segmentasyon, pazar segmentasyonunun en yaygın biçimi olarak öne çıkıyor. Bu muhtemelen, tüketicilerin net ölçü skalalarına yerleştirilmesi nedeniyle daha kolay anlaşılabilir olmasından kaynaklanıyor. Bilgi kolayca yorumlanabilir, nispeten kolayca toplanabilir ve bir araştırmadan diğerine kolayca aktarılabilir. Yaş, cinsiyet, aile büyüklüğü ve tipi, gelir, eğitim düzeyi, ırk ve ulusal köken gibi yaygın demografik değişkenler kullanılır. Bu değişkenlerin kombinasyonları, segment oluşturmadaki özgünlük derecesine bağlı olarak bazen kullanılır. (Kotler, 1980).

Psikografik veya yaşam tarzı segmentasyonu, açıklanması biraz daha zor hale gelir, çünkü artık net bir şekilde tanımlanabilir, nicel ölçümleri incelemiyoruz, ancak sosyal sınıf ve yaşam tarzı gibi konulara odaklanıyoruz. Psikografik, demografik bir çalışma belirli veya uygulanabilir segmentler üretmezse, araştırmada bir sonraki adım olarak işlev görebilir.

Temelde bir pazarı segmente ayırmak için psikografi kullanıldığında, amaç, bir kişinin içsel özelliklerini o pazarın anlayışına entegre etmeye çalışmaktır. Yaş, cinsiyet veya medeni durum yerine kişilik özellikleri, değerler ve inançlar ile yaşam tarzı göz önüne alınır. (Kotler, 1980).

Davranışsal Segmentasyon değişkenleri grubu davranışsal değişkenlerdir. Bu alanlar satın alma durumu, aranan faydalar, kullanıcı durumu, kullanım düzeyi, sadakat derecesi, hazır olma aşaması ve pazarlama faktörü hassasiyetini içerir. Genel olarak, tüketiciler ürün bilgisi, tutum veya ürüne karşı gösterdikleri tepki temelinde segmente edilir. (Kotler, 1980).

2.3.2 Pazar Segmentasyonunda Kullanılan Yöntemler

Çalışmanın bu bölümünde, pazar segmentasyonu için yaygın olarak kullanılan RFM, LRFM ve RFMV modelleri detaylı bir şekilde açıklanacak ve bu modellerin çeşitli kullanım alanlarına odaklanılacaktır. Bu modeller, işletmelerin müşterilerini daha iyi anlamasına ve özelleştirilmiş pazarlama stratejileri oluşturmasına yardımcı olarak rekabet avantajı elde etmelerini sağlar. Bu bölüm, RFM, LRFM ve RFMV modellerinin kapsamlı bir şekilde anlaşılmasını ve işletmelerin bu modelleri etkili bir şekilde kullanmasını destekleyecektir.

2.3.2.1 RFM (Recency-Frequency-Monetary) Analizi

RFM analizi, işletmelerin müşteri davranışlarını anlamak, müşteri segmentasyonu yapmak ve pazarlama stratejilerini kişiselleştirmek amacıyla kullanılan güçlü bir araçtır. Müşteri ilişkilerini yönetmek ve pazarlama stratejilerini geliştirmek, herhangi bir işletmenin başarısı için kritik öneme sahiptir. Bu noktada, RFM analizi, müşteri davranışlarını anlamak ve onları etkili bir şekilde segmente etmek için kullanılan bir tekniktir.

RFM analizi, büyük veri tabanındaki müşterileri üç değişkenle ayırarak önemli müşterileri belirlemeye yardımcı olan bir pazarlama tekniğidir. Bu üç değişken müşteri tüketimi aralığı, sıklığı ve tutarıdır. RFM modeli, müşteri sadakati değerlendirmek için Recency (Güncellik), Frequency (Sıklık) ve Monetary (Parasallık) olarak üç kriteri ele alır. (Nimbalkar & Shah, 2013)

Güncellik (R): Bu, bir müşterinin ne kadar yakın bir zamanda bir satın alma gerçekleştirdiğine referans verir. Daha yakın zamanda satın alma yapan müşteriler genellikle daha değerli olarak kabul edilir.

Sıklık (F): Bu, bir müşterinin ne sıklıkta satın alma yaptığını ölçer. Sık sık alışveriş yapan müşteriler, nadiren alışveriş yapanlardan daha değerli olarak kabul edilir.

Parasallık (M): Bu, bir müşterinin satın almalarının toplam mali değerini temsil eder. Daha fazla para harcayan müşteriler genellikle daha değerli olarak kabul edilir.

İşletmelerin RFM analizine gereksinim duymaları birçok sebepten kaynaklanabilmektedir. RFM analizi, müşterileri Recency (güncellik), Frequency (sıklık) ve Monetary (parasallık) değerlere göre segmente etme yeteneği sağlar. Bu segmentasyon, işletmelerin müşteri tabanını daha iyi anlamalarına ve farklı müşteri gruplarına özel pazarlama stratejileri oluşturmalarına yardımcı olur. Analiz, işletmelere en değerli ve potansiyel olarak sadık müşterilerini belirleme konusunda yol göstermektedir. En son alışveriş yapan, sık alışveriş yapan ve yüksek miktarlarda harcama yapan müşterileri tanımlamak, işletmelerin bu müşterilere özel teklifler ve avantajlar sunmalarını sağlar. Dahası müşteri davranışlarına dayanarak pazarlama stratejilerini kişiselleştirmek için kullanılır.

Örneğin, uzun bir süre alışveriş yapmamış ancak yüksek değerde alışveriş yapan bir müşteriye özel indirim teklifleri veya hatırlatıcı kampanyalar düzenlenebilir. İşletmelere veri odaklı kararlar alabilme yeteneği kazandırır. Gerçek verilere dayanarak müşteri davranışlarını değerlendirmek, işletmelerin stratejik planlamalarını daha sağlam temellere oturtmalarına olanak tanır. Sınırlı kaynakları daha etkili bir şekilde kullanımını planlar. Pazarlama çabalarını belirli müşteri gruplarına odaklamak, maliyetleri azaltabilir ve daha yüksek dönüşüm oranları elde etmelerine olanak tanır.

RFM analizi yapılırken müşterileri segmente edebilmek için skorlama yöntemi kullanılmaktadır. RFM skorlamanın temel amacı, müşteri davranışlarını sayısal verilere dönüştürerek, gelecekteki davranışları tahmin etmek ve daha etkili segmentasyon kararları alabilmektir. Müşteri davranışlarını zaman içinde sayısal bir formata çevirebilmek, gelecekteki eğilimleri daha iyi anlamak ve hedefe yönelik stratejiler geliştirmek açısından kritiktir.

RFM skorlama yapılırken birçok değerlendirme yöntemi kullanılmıştır. En yaygın skorlama yöntemi, müşterileri en iyi performans gösterenden en düşük performans gösterene doğru sıralamaktır. Müşteriler daha sonra beş eşit gruba ayrılır, en iyi müşterilere 5, en kötü müşterilere 1 puan verilir.

Güncellik skoru için müşteriler, son satın alma tarihlerine göre sıralanır ve gün sayısı ne kadar az ise, skor o kadar iyidir. Sıklık için müşteriler, satın alma sayılarına göre sıralanır ve satın alma sayısı ne kadar yüksekse, skor o kadar iyidir. Parasallık skoru için müşteriler, harcanan miktarlara göre sıralanır ve miktar ne kadar yüksekse, skor o kadar iyidir. Her müşteri skorlandığında, yeni bir göreli segmentasyon şeması oluşturulur. Bu yaklaşım, müşteri davranışlarını sayısal olarak ölçmenin ve gelecekteki projeksiyonlar oluşturmanın avantajlarına sahiptir. Nispeten en iyi müşteriler her zaman 5,5,5 kategorisine yerleştirilir. Her müşteri skorlamasıyla birlikte, otomatik olarak değişen kesim noktalarını belirlemek önemlidir.

Müşteri beşlisi yönteminin bir avantajı, her bir segmentte eşit sayıda müşteri oluşturmasıdır. RFM için beş eşit gruptan toplamda 125 eşit büyüklükte segment elde edilir. İlk analiz, tüm müşterilere ulaşmayı içerir; her bir hücrenin performansını incelemek (örneğin, hücre tanımları: 4,3,5 veya 2,3,3 gibi) ve müşteri segmentlerinin farklı performanslarını anlamaktır. (Miglautsch, 2000)

RFM skorlarını doğrudan birleştirmek mümkündür. En iyi müşterilerin bileşik skoru 15 (5+5+5) iken, en kötü müşterilerin minimum skoru 3 (1+1+1) olacaktır. Birçok müşterinin 7 veya 8 skoruna sahip olması ve bunları sıralamanın zor olması muhtemeldir. Ayrıca, onlarca yıllık doğrudan posta pazarlaması deneyimi, en son müşterilerin, birkaç tekrarlanan posta gönderimini görmezden gelenlerden daha değerli olduğunu öne sürmektedir. Bu bileşik formülü güçlendirmek için birçok postacı, R 5, F 2 ve M 1'i çarpar. Bu, en iyi müşterilere 30 (5x3) (5x2) (5x1) bileşik skoru verir. Bu, en son isimlere daha fazla güç vermenin yanı sıra sıklığı da biraz arttırır. (Miglautsch, 2000)

2.3.2.2 RFMV (Recency-Frequency-Monetary-Variety) Analizi

RFMV, müşteri segmentasyonu ve pazarlama stratejilerini belirleme amacıyla kullanılan bir analiz yöntemidir. Bu analiz, müşterilerin değerlerini ölçerek, pazarlama çabalarının bu müşteri segmentlerine odaklanmasını sağlar. RFMV'nin açılımı şu şekildedir:

Variety (Çeşitlilik): Müşterinin satın aldığı ürün veya hizmet kategorilerinin çeşitliliğini ifade eder. Bu, müşterinin çeşitli ürün veya hizmetlere olan ilgisini gösterir. Çeşitli ürünleri satın alan müşteriler, genellikle daha geniş bir hedef kitleye hitap edebilir. (Moghaddam, Abdolvand, & Harandi, 2017)

RFMV analizi, bu dört ölçümü kullanarak müşterileri gruplara ayırır. Bu gruplar, pazarlamacılara belirli müşteri segmentlerine özel stratejiler geliştirme ve pazarlama çabalarını optimize etme imkânı tanır. Örneğin, "yeni müşterilere özel teklifler" veya "yüksek maddi değere sahip müşterilere özel sadakat programları" gibi stratejiler uygulanabilir. Bu analiz, müşteri tabanını daha iyi anlamak, pazarlama bütçesini daha etkili bir şekilde kullanmak ve müşteri memnuniyetini artırmak için kullanılabilir. Ancak, RFMV analizi tek başına yeterli değildir; diğer pazarlama stratejileri ve müşteri ilişkileri yönetimi (CRM) uygulamalarıyla birlikte kullanılması daha etkili sonuçlar doğurabilir.

Ürün çeşitliliği gibi temel bir değişken, müşteri davranışını anlamak ve müşterileri sınıflandırmak için kullanılabilir. Müşterilerin farklı ürünleri tercih etme eğilimleri, pazarlama stratejilerinin daha iyi uyarlanması için önemli bir gösterge olabilir. Bu nedenle, bu çalışma, RFM modeline bir değişken ekleyerek (RFMV modeli), müşterileri ürün çeşitliliği temel alınarak kümelemeyi amaçlamaktadır. (Moghaddam, Abdolvand, & Harandi, 2017)

K-ortalama algoritması kullanılarak yapılan kümeleme sonuçları, ürün çeşitliliği değişkeninin müşteri değerini daha iyi hesaplamada etkili olduğunu ve RFMV modelinin daha doğru müşteri kümeleme ve değerleme sağladığını göstermiştir. Bu sonuçlar, işletmelerin müşteri davranışını anlamak ve pazarlama stratejilerini optimize etmek için ürün çeşitliliği gibi önemli değişkenleri dikkate almalarının önemini vurgular. (Ozkan, 2021)

Ürün çeşitliliği, müşteri davranışını değerlendirmenin temel unsurlarından biridir. Bu nedenle, işletme-işletme (B2B) iletişiminde bu faktörü incelemek, yenilikçi bir yaklaşımı temsil etmektedir. Bu bağlamda, müşteri değerini artırmak için yukarı satış ve çapraz satış stratejileri oldukça önemlidir. Bu stratejilere dayanarak, RFM modeline ürün çeşitliliği (V) değişkenini ekleyerek modeli iyileştirmeye yönelik bir çaba içerisindeyiz. Bu girişim, müşteri tanıma sürecine katkı sağlayacak ve B2B sektöründe müşterinin davranışını daha kesin bir şekilde anlamamıza yardımcı olacaktır. Ürün çeşitliliği, müşteri davranışını değerlendirmenin temel unsurlarından biridir. Bu nedenle, işletme-işletme (B2B) iletişiminde bu faktörü incelemek, yenilikçi bir yaklaşımı temsil etmektedir. Bu bağlamda, müşteri değerini artırmak için yukarı satış ve çapraz satış stratejileri oldukça önemlidir.

Bu stratejilere dayanarak, RFM modeline ürün çeşitliliği (V) değişkenini ekleyerek modeli iyileştirmeye yönelinmiştir. Bu girişim, müşteri tanıma sürecine katkı sağlayacak ve B2B sektöründe müşterinin davranışını daha kesin bir şekilde anlamamıza yardımcı olacaktır. (Moghaddam, Abdolvand, & Harandi, 2017)

2.3.2.3 LRFM (Lengh-Recency-Frequency-Monetary) Analizi

Müşterinin uzun süreli ilişkiler, müşterinin markaya olan bağlılığını ve değerini dikkate alarak, RFM modelinin genişletilmesi hedeflenmiştir. RFM modeli genişletilerek uzunluk (L) özelliği eklenerek LRFM modeli oluşturulmuştur.

LRFM analizi, müşteri değerlendirmesinde kullanılan bir modeldir ve dört ana özellikten oluşur: Uzunluk (Length), Güncellik (Recency), Sıklık (Frequency) ve Parasallık (Monetary). Uzunluk özelliği, müşterinin firmanızla olan ilişkisinin süresini temsil eder ve genellikle ilk alışverişten bu yana geçen zamanı içerir. Bu, müşteri sadakati ve bağlılığına dair önemli bilgiler sağlar. LRFM modeli, RFM modelini genişleterek müşteri değerlendirmelerini daha kapsamlı ve müşterinin tüketim davranışlarına daha yakın bir şekilde ele almayı amaçlar. Bu, müşteri segmentasyonu, pazarlama stratejileri ve müşteri sadakati yönetimi açısından daha etkili kararlar almanıza yardımcı olabilir. Bu özellikler, müşterilerin davranışlarını ve değerlerini anlamak amacıyla kullanılır.

Uzunluk (Length): Müşteri ilişkisinin ne kadar süredir devam ettiğini ifade eder. Bu özellik, müşterinin firmanızla ne kadar süredir etkileşimde bulunduğunu gösterir. Genellikle bu süre, ilk alışverişten bu yana geçen zamanı ifade eder. (Alvandi, Fazli, & Abdoli, 2012)

LRFM analizi, bu dört özelliği bir araya getirerek her müşteriyi bir skor veya segmente ayırır. Bu skorlar, müşterilerin değerini belirlemek ve onlara özel pazarlama stratejileri oluşturmak için kullanılabilir. Örneğin, yüksek LRFM skorlarına sahip müşterilere odaklanarak, en değerli müşterilere özel teklifler veya avantajlar sunabilirsiniz. Bu analiz, müşteri segmentasyonu, kişiselleştirilmiş pazarlama ve müşteri ilişkileri yönetimi stratejileri için önemli bir araçtır.

3. PAZAR SEGMENTASYONUNDA KULLANILAN YÖTEMLERİN LİTERATÜR TARAMASI

Çalışmanın bu bölümünde, benzer konular üzerine daha önce gerçekleştirilmiş olan araştırmalar ve çalışmalar detaylı bir şekilde incelenecektir. Literatür taraması yapılırken, konuyla ilgili yayınlanmış makaleler ve diğer bilimsel kaynaklar üzerinde kapsamlı bir araştırma gerçekleştirilmiştir. Bölüm sonuna literatür taramasına ait tablo eklenmiş olup özet hali sunulacaktır.

Şentürk ve Alp (2023) çalışmalarında RFM analizi kullanılarak, mevcut müşterinin davranışlarını tanımlamak, müşterileri segmentlere ayırmak ve pazarlama bakış açısıyla bu segmentler için stratejiler oluşturmak amaçlanmıştır. Çalışmada kullanılan veri seti 85328 adet 2021 yılına ait İstanbul bölgesindeki e-ticaret müşteri verisini içermektedir. RFM skorları her satır için toplanarak 3 ile 15 arasında değişen değerler bulunmuş bu değerlere karşılık müşteriler bad, bronze, silver gibi kategorize edilmiştir. Müşterilerin hangi gruplarda olduğu ve nasıl bir pazarlama stratejisi izlenmesi gerektiğine karar verilmiştir.

Pakyürek, Yıldız ve Kestepe (2018) çalışmalarında Demografik bilgiler (isimsizlestirilmiş), otel tercihleri, rezervasyon sayıları, tarihleri ve rezervasyon kanalı (web, acente) gibi veriler kullanılarak doğal kümelenmeleri belirleyerek misafir davranışlarını incelemiştir. Bu bağlamda, hizmetleri ve satış stratejilerini, misafirlerin bu kümeler içindeki davranışlarına göre özelleştirmiştir. K-ortalama algoritmasıyla bireyleri kümeler halinde düzenlemiş ardından bu kümeleri belirleyen temel özellikleri karar ağacı yaklaşımıyla çıkarmıştır. Bu özellikler arasında, kişinin ürün satın alma kanalı, belirli ürün tercihleri, rezervasyon süresi, mevsimsel tercihleri gibi faktörler bulunmaktadır. Bu özelliklerin her kümelenmede önemli ölçüde değişiklik göstermesi, çözümün genel olarak doğru ve seçilen özelliklerin etkili olduğunu göstermektedir. Bu çalışma, grup özelliklerine uygun kampanya ve ürün paketlerinin başarılı bir şekilde oluşturulmasında kilit bir rol oynamaktadır.

Sohrabi ve Khanlari (2007) çalışmalarında müşteri CLV'sini belirlemek ve (RFM) ölçümlerine dayanarak segmentlere ayırmak için K-Mean kümeleme yöntemi kullanış ayrıca kümeleme sonuçlarını onaylamak adına diskriminant analizi kullanılmıştır. Bu yöntemi uygulamak için gerekli veriler İran'daki özel bir bankanın şubesinden elde edilmiştir. Sonuç olarak, bu segmentasyon temelinde banka müşterileri için müşteri sadakati stratejileri önermektedir.

Gustriansyah, Suhandi ve Antony (2019) çalışmalarında RFM analizi için K-Means yöntemini kullanarak optimal küme sayısını belirlemek amacıyla Elbow Method, Silhouette Index, Calinski-Harabasz Index, Davies-Bouldin Index, Ratkowski Index, Hubert Index, Ball-Hall Index ve Krzanowski-Lai Index gibi sekiz geçerlilik indeksini içeren yeni bir yöntem önermiştir. Bu yöntemin ürün segmentasyonundaki verilerin nesnelliğini ve benzerliğini iyileştirerek stok yönetim sürecinin doğruluğunu artırabileceği savunulmuştur.

Olson, Cao, Gu ve Lee (2009) çalışmalarında sığır ürünlerinin satışını içeren bir veri seti üzerinde RFM yöntemlerini temel alarak incelemiştir. RFM'nin çeşitli varyasyonları gösterilmiş ayrıca, klasik veri madenciliği teknikleri olan lojistik regresyon, karar ağaçları ve sinir ağları da gösterilmiştir. Tüm veri madenciliği algoritmalarının öngörü doğruluğunda dikkate değer bir artış olduğu belirlenmiştir. Bu veri madenciliği algoritmalarının müşteri segmentasyonu bağlamında göreceli avantajları tartışılmıştır.

Belhadj (2021) çalışmadaki temel amaç müşteri değer analizi için kapsamlı bir metodoloji sunmaktır. İlk olarak, CLV kavramı, RFM modeli ve diğer ilgili konular gözden geçirilmektedir. Ardından, seçilen bir şirketin işlem veritabanı üzerinde bir durum çalışması sunulmaktadır. Müşterilerin ömür boyu değerini (CLV) belirlemek ve onları k-ortalama kümeleme yöntemine dayanarak segmentlere ayırmak için Ağırlıklı RFM (yenilik, sıklık ve maliyet) modeli kullanılmıştır. RFM modelinin göreceli ağırlıkları, analitik hiyerarşi süreci (AHP) ile belirlenmiştir. Bulgular, RFM ölçüleri kullanarak yapılan CLV analizinin şirketin müşterilerini daha iyi anlamasına ve en karlı müşterileri belirlemesine yardımcı olabileceğini göstermektedir. Bu nedenle, şirket müşteri ilişkilerini daha etkili bir şekilde sürdürmek için pazarlama stratejileri geliştirebilir.

Li, Wang ve Shen (2021) çalışmalarında edinilmiş bağışıklık yetmezliği sendromu (AIDS) hastalarında tedavi uyumluluğunu öngörmek amacıyla klasik Recency, Frequency, and Monetary (RFM) analizini kullanarak bir tahmin modeli oluşturmayı amaçlamaktadır. Şangay'daki AIDS polikliniğine başvuran 257.305 hastanın verileri üzerinde yapılan çalışmada, RFM modeli, k-ortalama kümeleme analizi ve C5.0 algoritması kullanılmıştır. Üç kere k-ortalama kümeleme analizi sonrasında, 10.614 hastadan oluşan iki gruba ayrılan hastalardan elde edilen veriler, RFM modeli ve C5.0 algoritması kullanılarak %100 doğruluk oranına sahip bir tahmin modeli oluşturulmasını sağlamıştır. Bu sonuçlar, hastaların tedaviye uyumluluğunu öngörmek için RFM modelinin ve veri madenciliği yöntemlerinin etkili bir şekilde kullanılabileceğini göstermektedir.

Stormi, Lindholm, Laine ve Korhonen (2020) çalışmalarında, orijinal ekipman üreticilerinin (OEM'ler) ürün odaklı hizmet müşterilerini, hizmet tüketiminin RFM analizi ile segmente etme yöntemlerini incelemektedir. İki büyük OEM'in karlı büyüme hedefi doğrultusunda gerçekleştirilen müdahaleci bir durum çalışmasına dayanmaktadır. RFM analizi için kullanılan veri seti, 2010-2016 tarihleri arasındaki bir bölgeden yapılan yedek parça satışlarını kapsamaktadır. Bu veri seti, yüzden fazla müşteriyi ve 2000'den fazla siparişi içermektedir. Büyük ürün tabanlarına sahip müşteri ortamlarında ürün odaklı hizmet yönetimini anlamak isteyenlerin strateji geliştirmesine katkı sağlamıştır.

Tuncer ve Karaboğa (2021) çalışmalarında Karaman bölgesinde faaliyet gösteren bir gıda perakende işletmesinin 6600 müşterisine ait verileri kullanılarak, RFM metriklerine dayalı olarak müşterilerin kümelere ayrılmasını ve pazarlama perspektifinden değerlendirilmesini amaçlamıştır. Analizde RFM ve k-ortalama teknikleri kullanılmıştır. Yapılan analiz sonucunda, toplamda altı müşteri kümesi belirlenmiştir. En karlı müşteri kümesi, en az karlı ve neredeyse terk edilmek üzere olan müşteri kitlesine karar verilmiş bu müşterilere uygun strateji belirlenmesi hedeflenmiştir.

Chen, Laing ve Guo (2012) çalışmalarında çevrimiçi perakendeci için müşteri odaklı iş zekası için veri madenciliği tekniklerinin kullanıldığı bir vaka çalışması sunulmaktadır. 1 Ocak 2011 ile 31 Aralık 2011 tarihleri arasında oluşturulan işlemler incelenmiştir. Bu süre zarfında toplamda 22,190 geçerli işlem gerçekleşmiş ve bunlar 4381 farklı geçerli posta kodu içermektedir. Analizin temel amacı, işletmenin müşterilerini daha iyi anlamasına yardımcı olmak ve bu nedenle müşteri odaklı pazarlamayı daha etkili bir şekilde yürütmektir. Recency, Frequency ve Monetary modeli temel alınarak, işletmenin müşterileri k-ortalama kümeleme algoritması ve karar ağacı çıkarsama kullanılarak farklı anlamlı gruplara ayrılmış ve her segmentteki tüketicilerin başlıca özellikleri net bir şekilde tanımlanmıştır. Bu amaçla, işletmeye tüketici odaklı pazarlama konusunda farklı öneriler sunulmuştur.

Başkol (2020) çalışmasında segmentasyonun önemini vurgulamış ve yerel bir perakendeciye ait bir veri tabanından elde edilen veriler kullanmıştır. Çalışmanın veri seti, bir yıllık zaman diliminde sadakat kartı kullanan 18975 müşterinin alışveriş kayıtlarını içermektedir. Her müşterinin RFM değerleri, Python programlama dili kullanılarak belirlenmiştir. RFM değerlerine göre segmente edilen müşteriler, sürekli olarak satın aldıkları makarna markalarına göre analiz edilmiştir. Uyum analizi için SPSS programı kullanılarak, bu segmentlerin hangi markalarla daha fazla ilişkide oldukları tespit edilmiştir.

Shih ve Liu (2003) çalışmalarında müşteri yaşam değerini (CLV) değerlendirmede RFM değişkenlerinin göreceli önemini belirlemek amacıyla analitik hiyerarşi sürecini (AHP) kullanır. Daha sonra, müşterileri ağırlıklı RFM değerlerine göre kümelemek için çeşitli kümeleme teknikleri uygulanır. CLV sıralamasını elde etmek için basit ağırlıklı toplam yaklaşımı kullanılarak müşteri segmentleri net bir şekilde belirlenir ve karşılaştırılır. Bu yaklaşımın kullanılabilirliği ve katkısı yöntemin bir donanım perakendecisine uygulanarak doğrulanır ve önerilen yöntemi değerlendirmek için kullanışlı bir pazarlama veri tabanı elde edilir. Son olarak, çalışma, önerilen yöntemi doğrulamak için üç farklı perspektifi tartışmaktadır. Bu çalışma, CLV sıralaması için etkili bir yöntem sunar ve bu nedenle pazarlama uygulayıcılarının daha etkili pazar segmentasyonu gerçekleştirmelerine katkı sağlamaktadır.

Özkan ve Deveci (2021) çalışmalarında 6 aylık bir alışveriş dönemini kapsayan 6406485 satırdan (alışveriş fişi) oluşan ve 60284 farklı müşteriyi içeren bir veri grubunu içermektedir. Çalışma, müşteri segmentasyonu için önerilen yeni bir modele odaklanmaktadır.

Kullanılan veriler RFM-V adı verilen bu modelde, "V" parametresi müşterinin alışveriş çeşitliliğini belirtir ve bu müşteri ilişkileri yönetimi literatüründe müşteri derinliğini tanımlamak için kullanılabilir. Ayrıca, bu modele V değişkeninin eklenmesiyle oluşturulan yeni bir Matris olan Müşteri-Ürün Derinlik Matrisi'ni önermektedir. M ve V parametrelerini içeren bu matris, müşterilerin derinliklerine göre dört farklı kategoride incelenebilir. Analiz sonuçları, sepet analizi verileri ile ilişkilendirilerek daha etkili pazarlama stratejileri oluşturmak ve başarılı promosyon önerileri sunmak için kullanılabilir.

Qadaki, Abdolvand ve Harandi (2017) çalışmalarında müşteri alışveriş davranışlarını sınıflandırmak, değerlendirmek ve modellemek amacıyla çeşitli algoritmalar ve teknikler kullanılmıştır. Kümeleme teknikleri ve k-ortalama algoritmaları, 924 normalize edilmiş müşteri kaydında CRISP-DM metodolojisi çerçevesinde uygulanmıştır. Elde edilen kümeler üzerinde ANOVA testi ve Duncan'ın post hoc testi ile belirgin kümeler tespit edilmiştir. Son olarak, R, F, M, V değişkenlerini ağırlıklandırmak ve her müşterinin değerini hesaplamak için hiyerarşik analiz yöntemi kullanılmıştır. Yapılan modelleme sonuçları, ürün çeşitliliği değişkeninin RFM modeline göre daha doğru kümeleme sağladığını göstermektedir.

Tyasnurita ve Kafif Ibrahim (2022) çalışmlarında UD. Antar Berkah Group'taki müşteri segmentasyonunu LRFM (Uzunluk, Güncellik, Sıklık ve Parasal) modeli ve k-ortalama algoritması kullanarak gerçekleştirir. Elbow yöntemi ile belirlenen ideal küme sayısı kullanılarak müşteriler segmente edilir. Ardından, her kümenin Müşteri Yaşam Değeri (CLV) Analytical Hierarchy Process (AHP) yöntemiyle belirlenen ağırlıklarla hesaplanır. Bu sonuçlar, UD. Antar Berkah Group ile iş birliği içinde tutma stratejileri oluşturmak için kullanılır. Çalışma, günlük işlem verileri ve tüketici harcamaları üzerinden müşteri özelliklerini başarıyla belirleyerek iki farklı LRFM tabanlı küme tanımlar. Bu küme farklarına dayalı olarak her birine özgü tutma stratejileri geliştirilir.

Jamunadevi, Tamil Selvan , Govindarajan, Saravanan ve Janaki (2021) çalışmalarında pandemi sürecinde insanların çevrimiçi alışverişe olan eğilimlerini ve pandemi sona erdikten sonra bu alışkanlıklarını sürdürme niyetlerini araştırmayı amaçlamıştır. Veriler, sosyal medya üzerinde gerçekleştirilen bir anketle toplanmış; ankette 12 farklı soru bulunmakta ve 615 katılımcıdan yanıt alınmıştır. Çalışma, LRFM modeli ve k-ortalama algoritması kullanılarak anket verilerini detaylı bir şekilde analiz etmektedir. Silhouette analizi, kümeleme kalitesinin değerlendirilmesinde kullanılmıştır. Bulgular, insanların evde kalma döneminde çevrimiçi alışverişe olan ilgilerini sürdürdüğünü ve pandemi sonrasında da çevrimiçi alışverişi devam ettirme niyetinde olduklarını ortaya koymaktadır.

Alvandi, Fazli ve Seifi Abdoli (2012) çalışmalarında bankacılık hizmetlerine özgü dört temel boyutta şekillenen LRFM müşteri ilişkisi modelini kullanarak müşteri yaşam değeri (CLV) modelini sunmaktır. Müşterileri sınıflandırmak ve pazarlama stratejilerini belirlemek amacıyla gerçekleştirilen kümeleme analizini içermektedir. İran'da 32 yıllık finansal geçmişe sahip olan devlet bankasından elde

edilen gerçek veriler üzerinde uygulanmıştır. Kümeleme sürecinin geçerliliği, R-kare endeksi ile analiz edilmiştir ve sonuçlar, müşteriler arasında dokuz farklı küme deseni göstermektedir. Bu kümeleme perspektifinden hareketle, müşteri stratejileri önerilmiştir. Çalışma müşteri ilişkileri yönetimi için yeni fikirler sunmaktadır.

Khajvand, Zolfaghar, Ashoori ve Alizadeh (2011), çalışmalarında günümüz iş dünyasında müşteri değerine verilen artan öneme odaklanılarak, bir sağlık ve güzellik şirketinin yaklaşık 7,000 kayıttan oluşan bir yıllık satın alma işlemlerine ait veri toplanmıştır. Müşterileri segmente etmek için K-ortalama kümeleme yöntemi kullanılmıştır. İki farklı yaklaşım incelenmiş: ilk olarak, RFM (Yenilik, Frekans ve Monetarizasyon) pazarlama analiz yöntemi ile müşteri segmentasyonu yapılmış, ikinci olarak ise önerilen genişletilmiş RFM analiz yöntemi kullanılarak segmentasyon gerçekleştirilmiştir. Bu yeni yöntemde RFM'ye ek olarak "Count Item" adı verilen bir parametre eklenmiştir. Sonuçlar karşılaştırıldığında, Count Item'ın RFM yöntemine eklenmesinin kümeleme sonuçları üzerinde bir fark yaratmadığı gözlemlenmiştir. Bu nedenle, her bir segment için ağırlıklı RFM yöntemi kullanılarak hesaplanan CLV, pazarlama ve satış stratejilerinin açıklanmasında kullanılabilir. Bu çalışma, müşteri ilişkileri yönetimi stratejilerinin geliştirilmesine katkıda bulunabilir.

Aleksandrova (2018) çalışmasında odak noktası, müşteri kaybı tahminine yönelik RFM analizi ve makine öğrenimi algoritmalarının bir kombinasyonunu önermektir. Bulgular, Bulgaristan'daki bir bölgesel beton üretim şirketinin ERP sisteminden elde edilen veri seti üzerinden sunulmuştur. RFM puanları, muayene son tarihinden önceki 6 aylık dönem için her müşteri için hesaplanmış ve tahmin modelleri için hedef değer, RFM analizini takip eden 6 ay içinde müşterinin bir işlem gerçekleştirip gerçekleştirmediğini gösteren bir kayıp metriği olarak belirlenmiştir. İki sınıflı güçlendirilmiş karar ağaçları, iki sınıflı yapay sinir ağları, iki sınıflı destek vektör makineleri ve iki sınıflı lojistik regresyon gibi çeşitli makine öğrenimi algoritmaları deneylerde kullanılmıştır. Bu deneyler, Azure Machine Learning Studio'da gerçekleştirilmiştir. Sonuçlar, RFM puanlarının ve metriklerinin sınırlamalarına rağmen, şirketlerin müşteri kaybını yeterli güvenle tahmin edebilecekleri konusunda olumlu bir görünüm sunmaktadır. Bu çalışma, sınırlı veri kaynaklarına sahip küçük ve orta ölçekli işletmeler için müşteri kaybı tahmininde etkili bir metodoloji sunmaktadır.

Sabuncu, Türkan ve Polat (2020) çalışmalarında, İstanbul'daki bir akaryakıt istasyonundan elde edilen gerçek müşteri verilerini kullanarak, RFM analizi ile müşterilerin yaşam boyu değerine göre segmentasyon ve profilleme üzerine bir vaka çalışması sunmaktadır. Veri seti, 2016'nın ilk yarısında 1015 müşterinin varış sıklığı, son varış tarihi ve toplam harcama miktarını içermekte olup, müşterilerin 10 tanımlayıcı değişkenine sahiptir. İlk olarak, akaryakıt istasyonu müşterilerinin demografik özellikleri betimsel istatistiklerle analiz edilmiştir. SPSS programı kullanılarak müşterilerin RFM puanları hesaplandı ve kümelenme analizi ile müşteriler, RFM skorlarına göre 5 segmente ayrıldı.

Analiz sonuçları, akaryakıt istasyonu yöneticilerinin en değerli müşteri olarak otomobil sürücülerini görmelerine rağmen, en değerli müşterilerin Kamyon şoförleri olduğunu öne sürmektedir. Çalışmanın sonunda, VIP ve GOLD olarak adlandırılan iki en değerli segmentin müşteri profillerine dayanarak önerilerde bulunulmuştur.

Parikh ve Abdelfattah (2020) çalışmalarında, çevrimiçi işlemlerde müşteri satın alma davranışlarına yönelik stratejiler sunmak amacıyla kümeleme algoritmaları ve Recency, Frequency, and Monetary value (RFM) analizinin nasıl uygulanabileceğini araştırmaktadır. Perakende veri seti üzerinde RFM analizi yapılırken, Mean-shift, Density-Based Spatial Clustering of Applications with Noise (DBSCAN), Agglomerative Clustering ve K-Means gibi kümeleme algoritmaları kullanılmıştır. Bu algoritmaları karşılaştırarak, RFM değerlerine dayalı olarak değerli müşteri grupları tespit edilmiştir.

Chang, Chang ve Lin (2015) çalışma, müşteri değerini açıklamak için yaygın olarak kullanılan RFM modelindeki eksikliklere odaklanmaktadır. Sağlık hizmeti sistemlerinde hizmet kapasitesinin sınırlamalarını göz önüne alarak, müşteri değeri analizi için yeni bir konsept önermektedir. Önerilen geliştirilmiş RFM modeli, müşteri kalış süresini dikkate alan Moneter ölçümünü ayarlamaktadır. Çalışma, diş sağlığı hizmetlerine uygulanarak müşteri değerlerini daha doğru ve hizmet sistemine daha uygun bir şekilde ölçmüştür. Hasta segmentasyonu, entegre müşteri değeri matrisi ve geleneksel/geliştirilmiş RFM modeli ile gerçekleştirilmiştir. Sonuçlar, önerilen geliştirilmiş RFM modelinden elde edilen hedef hasta segmentinin, hasta sayısı, ortalama yaş ve ortalama tedavi süresi açısından hafif bir azalma gösterdiğini, ancak ortalama maliyet ve geliştirilmiş ortalama maliyetin geleneksel RFM modelinden daha üstün olduğunu göstermektedir. Bu çalışma, geliştirilmiş modelin hedef hastaların daha objektif ve etkili bir şekilde segmentasyonunu gerçekleştirdiğini ortaya koymaktadır.

Kutaran G. (2022) çalışmasında lastik firmasının müşteri elde tutma sorunu üzerinden, 354 kullanıcının verileri kullanılarak Python'da yazılan RFM analizi kodları ile firmanın 3 boyutlu RFM analizi grafiği oluşturulmuştur. Çalışmada RFM analizi ve veri madenciliği kullanarak müşteri sınıflandırması, sadık müşteri tespiti ve firmaların müşteri sadakatini artırmak için RFM analizinin etkili bir model olduğunu vurgulamaktadır.

Chang vd. (2013) bir giyim mağazasının müşteri değerlerini değerlendirmek için LRFM (length, recency, frequency, and monetary) modeli ve kümeleme tekniklerini nasıl kullandığını incelemektedirler. Önce, Self-organizing maps kullanılarak en iyi küme sayısı belirleniyor, ardından L, R, F ve M değişkenleriyle 551 müşteri K-means yöntemiyle on iki kümeye ayrılmaktadır. Sonuçlar ise 5'in en önemli küme olabileceğini göstermiştir. LRFM modeli ve kümeleme tekniklerinin uygulanmasıyla, giyim mağazası kaynaklarını etkili bir şekilde yönetebilir, yüksek değerli müşterileri tanımlayabilir ve farklı kümeler için özelleştirilmiş pazarlama stratejileri geliştirmesi hedeflenmiştir.

Tablo 3-1: Literatür taraması.

YAZAR	ÇALIŞMA	UYGULAMA/YÖNTEM
Şentürk ve Alp (2023)	Perakende Sektöründe Rfm Analizi ile Müşteri Segmentasyonu	RFM skorlama
Pakyürek, Kestepe ve Yıldız (2018)	Müşterilerin GSP Analizi Kullanarak Kümelenmesi,	K-ortalama
Sohrabi ve Khanlari (2007)	Customer Lifetime Value (CLV) Measurement Based on RFM Model	K-ortalama ve diskriminant analizi
Gustriansyah, Suhandi ve Antony (2019)	Clustering Optimization in RFM Analysis Based On K-Means	K-ortalama ve 8 geçerlilik endeksi (Elbow Method, Silhouette Index, Calinski-Harabasz Index, Davies-Bouldin Index, Ratkowski Index, Hubert Index, Ball-Hall Index ve Krzanowski-Lai Index)
Olson, Cao, Gu, ve Lee (2009)	Comparison of customer response models	K-ortalama, lojistik regresyon, karar ağaçları ve sinir ağları
Belhadj (2021)	Customer Value Analysis Using Weighted RFM model: Empirical Case Study	K-ortalama ve AHP
Li, Wang ve Shen (2021)	Adherence predictor variables in AIDS patients: an empirical study using the data mining-based RFM model	K-ortalama ve C5.0 algoritması
Stormi, Lindholm, Laine ve Korhonen (2020)	RFM customer analysis for product-oriented services and service business development: an interventionist case study of two machinery manufacturers	RFM skorlama
Tuncer ve Karaboğa (2021)	RFM Metriklerini Kullanarak Kümeleme Yöntemi ile Müşteri Bölümlendirme: Perakende Sektöründe Bir Uygulama	K-ortalama

Chen, Laing ve Guo (2012)	Data mining for the online retail industry: A case study of RFM model-based customer segmentation using data mining	K-ortalama ve karar ağacı
Başkol (2020)	RFM ve Uyum Analizi Kullanılarak Müşteri Segmentasyonunun Belirlenmesi	RFM skorlama
Shih ve Liu (2003)	A method for customer lifetime value ranking - Combining theanalytic hierarchy process and clustering analysis	RFM skorlama ve AHP
Ozkan ve Deveci (2021)	A Customer Segmentation Model Proposal for Retailers: RFM-V	Müşteri-Ürün Derinlik Matrisi
Qadaki, Abdolvand ve Harandi (2017)	A RFMV Model and Customer Segmentation Based on Variety of Products	K-ortalama, ANOVA testi, AHP
Tyasnurita ve Kafif Ibrahim (2022)	LRFM Model Analysis for Customer Segmentation Using K-Means Clustering	K-ortalama ve AHP
Jamunadevi, Tamil Selvan , Govindarajan, Saravanan ve Janaki (2021)	LRFM Model for Customer Purchase Behaviour Using Kmeans Algorithm	K-ortalama
Alvandi, Fazli ve Seifi Abdoli (2012)	K-Mean Clustering Method For Analysis Customer Lifetime Value With LRFM Relationship Model In Banking Services	K-ortalama, R kare endeksi

Khajvand, Zolfaghar, Ashoori ve Alizadeh, (2011)	Estimating customer lifetime value based on RFM analysis of customer purchase behavior: case study	K-ortalama
Aleksandrova (2018),	Application Of Machine Learning For Churn Predıction Based On Transactional Data (Rfm Analysis),	Karar Ağaçları, İki Sınıflı Yapay Sinir Ağları, İki Sınıflı Destek Vektör Makineleri ve İki Sınıflı Lojistik Regresyon
Sabuncu, Türkan ve Polat (2020)	Customer Segmentation And Profiling With RFM	Kümeleme Analizi
Parikh Y ve Abdelfattah E, (2020)	Clustering Algorithms and RFM Analysis Performed on Retail Transactions	Mean-shift, Density-Based Spatial Clustering of Applications with Noise (DBSCAN), Agglomerative Clustering ve K-Means
Chang, Chang ve Lin (2015)	Analyzing Patient Value by Modifying RFM Model With Consideration of The Limitation of Service Throughput:	Müşteri değeri matrisi ve RFM skorlama
Kutaran G. (2022)	RFM Analizi (Recently Frequance Monetary Value, Güncellik Sıklık Para)	K-ortalama
Chang vd (2013)	A case study of applying LRFM model and clustering techniques to evaluate customer values	K-ortalama

4. UYGULAMA

Tezin bu bölümünde öncelikle uygulamanın konusu, amacı ve öneminden bahsedilecektir. Daha sonrasında modeller tanıtılacaktır. Analiz edilip üzerinde sözü geçen modeller gerçek veriler kullanılarak test edilecek, analiz ve sonuçlara yer verilecektir.

4.1 Uygulamanın Konusu

Bu uygulama, biyoteknoloji sektöründe pazar segmentasyon modellerinin incelenmesi üzerine odaklanmaktadır. Farklı pazar segmentasyon modellerini karşılaştırarak biyoteknoloji sektöründe nasıl kullanılabileceğini araştırmaktır.

4.2 Uygulamanın Amacı

Bu uygulama, biyoteknoloji (B2B) sektöründe faaliyet gösteren şirketlere, müşteri tabanlarını daha iyi anlama, hedef kitlelerini belirleme ve pazarlama stratejilerini optimize etmeyi amaçlamaktadır. RFM analizi genellikle B2C (işletmeden tüketiciye) pazarlama stratejilerinde kullanılsa da B2B (işletmeden işletmeye) sektöründe de uygulanabilir. Bu çalışma ile de B2B sektörü ele alınarak modeller açıklanmaktadır. CRM üzerinden elde edilen müşteri verileri, veri madenciliği teknikleriyle pazar segmentasyonu yapılarak, şirketin geçmiş verilerine bakarak gelecek hareketlerinin planlamasında, müşterilerin kimliklerini tespit etme ve onlara tutundurma gibi birçok önemli konuda rehberlik sağlamaktadır. Bu analizler sayesinde, müşterilerin özelliklerini daha iyi anlayabilir, ihtiyaçlarını ve tercihlerini belirleyebilir, hedef kitleyi daha iyi tanıyabilir ve pazarlama stratejilerini optimize edebilir. Bu çalışma, biyoteknoloji sektöründeki şirketlere rekabet avantajı sağlamak amacıyla müşteri verilerini etkin bir şekilde kullanarak yöntemlerin uygulanması ve karşılaştırılmasını hedeflemektedir.

4.3 Uygulamanın Önemi

Teknolojinin hızla geliştiği günümüz dünyasında işletmelerin rekabet edebilmesi için faaliyetlerini dijitalleştirmeden kaçınması mümkün olmamaktadır. Defter ve kâğıt kullanımının aksine birçok yazılım, program ve uygulama sayesinde artık büyük miktarda veri tutma imkânı bulunmaktadır. Bu noktada, müşteri ilişkileri yönetimi sistemleri (MİY) işletmelerin müşterileriyle olan ilişkilerini yönetmelerini, müşteri bilgilerini saklamalarını ve analiz etmelerini sağlayan yazılımlardır. Günümüzde küçük veya büyük sermayeli olsun bütün işletmeler, büyük olasılıkla müşteri ilişkileri yönetimi sistemlerine sahiptir.

Ancak, MİY tek başına işletme hakkında yeterli bilgi sağlama konusunda sınırlıdır. MİY verilerinizle analiz yaparak, müşterilerinizi daha iyi tanıyabilir ve müşterilerinizin istek ve ihtiyaçlarına uygun pazarlama stratejileri planlanabilir. Artan rekabet koşullarında bu işlemi her şirketin gerçekleştirebilmesi önemlidir. Bu çalışmada, işletmelerin elindeki MİY verilerinden yapabileceğiniz

analizler ve bu analizler için gereken veri setlerini açıklanacaktır. Müşteri yaşam boyu değerini belirlemek için RFM analiz modelini kullanılacaktır.

RFM (Recency, Frequency, Monetary) parametrelerini ele alan bir müşteri segmentasyon modelidir ve müşteri ilişkileri yönetimi ve veri tabanı pazarlamasında sıklıkla kullanılmaktadır. Ancak, geleneksel RFM analiz modeli araştırmacılar tarafından eksik bulunmuş V (Variety) ve L (Length) gibi ek faktörlerle birlikte farklı analiz yöntemi ele alınmıştır. İşletmeler gün geçtikçe büyümekte bununla birlikte hem müşteri kaybına uğramakta hem de yeni müşteriler kazanmaktadır. Kazanılan veya kaybedilen müşteriler hakkında bilgi sahibi olmak, her işletme için kritik bir öneme sahiptir. Birçok işletme, müşteri ilişkileri yönetimi (MİY) sistemleri aracılığıyla müşterilere ait verileri kaydedip işlemekte ve bu sayede rekabet avantajı elde etmeyi ve pazarını genişletmeyi hedeflemektedir. MİY verilerini çeşitli analizlerle değerlendirerek, işletmeler müşterileri hakkında daha derin ve anlamlı bilgiler elde edebilmektedirler.

4.4 Modellerin Uygulanması

Bir biyoteknoloji şirketinin müşteri davranış ve ihtiyaçları temel alınarak yeni bir pazar bölümlendirme yapısının oluşturulması ve her bir müşteri grubunun özelliklerine uygun müşteri stratejilerinin geliştirilmesini hedeflenmiştir. Bu amaçla, şirketin müşteri ilişkileri yönetimi (MİY) sistemi veri tabanından veriler temin edilerek bir veri seti oluşturulacaktır.

Araştırmanın evreni, RFM analizi için 02.01.2020 ile 06.12.2022 tarihleri arasında belirlenmiş ve şirketin belirlediği kriterlere uyan aktif müşteri havuzu içinde yer alan 228 firma olarak tanımlanmıştır. Bu evren, biyoteknoloji sektöründe faaliyet gösteren firmaları içermektedir ve veri madenciliği çalışması da bu sektördeki firmaların müşteri davranışlarına dayalı olarak gerçekleştirilecektir. Müşterilere ait kullanılan veri seti örneği Şekil1'de gösterilmiştir.

Şekil 4-1: Müşteri Veri Seti Örneği

	Sipariş No	Müşteri Adı	Satış Tarihi	Ürün Kodu	Ürün Adı	Miktar	Fiyat
0	SatSip04520	müşteri 1	2020-01-23	348701	FITC anti-human Lineage (CD3/14/19/20/56)	1.0	8415.00
1	SatSip04520	müşteri 1	2020-01-23	357406	FITC anti-human CD4	1.0	1700.00
2	SatSip04520	müşteri 1	2020-01-23	501420	PE/Cyanine7 anti-human IL-10	1.0	5015.00
3	SatSip04520	müşteri 1	2020-01-28	100333	Pacific Blue™ anti-mouse CD3ε	1.0	1517.25
4	SatSip04520	müşteri 1	2020-01-28	421101	TMB Substrate Set	1.0	505.75
...	...	...	...	...	...	...	...
9081	SatSip04386	müşteri 228	2022-07-29	04-4010	Decontamination Solution, 250 ml	2.0	1620.00
9082	SatSip04386	müşteri 228	2022-07-29	04-4012	Hypochloride Solution, 250 ml	2.0	1260.00
9083	SatSip04386	müşteri 228	2022-07-29	05-4012	Red Fluorescent Particles Conc. 5 ml	1.0	16848.00
9084	SatSip04386	müşteri 228	2022-07-29	05-4018	Calibration Beads/3 um-Ready to use (30 Test/3...	1.0	1422.00

Veri madenciliği teknikleri, müşteri davranışlarını inceleyerek müşteri gruplarını tanımlamak ve bu gruplara özgü ihtiyaçları ve eğilimleri anlamak için kullanılacaktır. Bu aşamada RFM (Recency, Frequency, Monetary), RFMV (Recency, Frequency, Monetary, Variety) ve LRFM (Length, Recency, Frequency, Monetary) analizleri uygulanacaktır.

4.4.1 RFM (Recency-Frequency-Monetary) Analizi

RFM analizi, müşterilerin satın alma geçmişine dayalı olarak segmentasyon yapmak için kullanılan bir pazarlama analizidir. Bu analiz için, müşterilerin satın alma tarihi, satın alma tutarı ve satın alma sıklığı gibi bilgileri içeren bir veri tabanına ihtiyaç vardır. Bu veri tabanı MİY sistemi tarafından sağlanabilir.

İlk aşamada, işin türüne ilişkin bir genel bakış elde edilir ve mevcut stratejilere ve iş yapısı göz önünde bulundurularak hedefler belirlenir (Larose, 2006). Bu çalışmada kullanılacak verileri sağlayan şirket, biyolojik sarf malzemeleri satan bir işletmedir ve müşteri tabanının büyük bir kısmı laboratuvarlar tarafından oluşmaktadır. RFM ile modelinin diğer davranışsal değişkenlerini değerlendirmek, müşterilerin eşdeğer değerlerine dayalı olarak benzerliklerini belirlemek ve yüksek değerli müşterileri tanımak için şirketi yetenekli hale getirmek amaçlanmıştır.

Verilerin toplanması, açıklanması ve veri kalitesinin değerlendirilmesini içerir. Genel olarak bu aşamanın amacı, hedefe ulaşmak için uygun veri kaynağını seçmektir. RFM analizi yapmak için şirketin MİY sistemi altyapısından çekilen veri setini kullanılacaktır. Bu veri seti, İstanbul'da bir biyoteknoloji şirketinin satış verilerini içerir. Veri tabanındaki bilgileri kullanarak, müşteri kodu, adı ve toplam satın alma miktarı dahil olmak üzere 1.000'den fazla müşterinin verileri veri tabanına kaydedilir. Bu aşamada Microsoft Excel kullanılarak çıktı raporları alınır ve ilk veri sıralamasının ardından endeks değerleri çıkarılır. Son olarak, gerekli değişkenler olan müşterilerin satın alma sayısı, müşterinin son satın alma tarihi çıkarılır. Ardından veriler modelleme için hazırlanır. Veri hazırlama, aykırı değerlerin çıkarılması ve veri normalizasyonu işlemini içerir. Bu çalışmada, 9000'den fazla kayıt toplanır; yinelenen veriler çıkarıldıktan ve her satın alma yapan firmalar gruplandırıldığında analizde kullanılacak veri sayısı 228 olarak belirlenmiştir. Veri, veri madenciliği araçları tarafından kullanılabilecek bir şekle dönüştürülür. Aşağıdaki Tablo1 dönüştürülmüş veriyi göstermektedir.

Tablo 4-1: Dönüşüm Tablosu

Başlangıç Verileri	Dönüştürülmüş Veri
Son satın alma tarihi	Güncellik (Recency)
Satın alma sayısı	Sıklık (Frequency)
Harcanan toplam tutar	Parasallık (Monetary)

MİY sisteminden alınan başlangıç verileri, Tablo4-1 formatında oluşturulmuştur. Bu tabloda RFM analizinde hesaplanacak her bir parametre verisi belirtilmiştir.

Tablo 4-2: CRM Veri Seti

Müşteri Adı	Satış Tarihi	Miktar	Fiyat
müşteri 1	23.1.2020	1,00	8.415,00
müşteri 2	28.1.2020	1,00	1.700,00
müşteri 3	30.1.2020	2,00	5.015,00

Verilerin dönüştürülmüş örneği ise Tablo4-2'de yer almaktadır. Bu veriler, RFM analizinin hesaplanabilmesi için temel oluşturmaktadır.

Tablo 4-3: Dönüşüm Veri Seti

Müşteri Adı	Güncellik	Sıklık	Parasallık
müşteri 1	34.0	66	1779974.35
müşteri 10	761.0	1	36087.49
müşteri 100	800.0	1	28560.0
müşteri 101	81.0	1	369245.0
müşteri 102	341.0	1	3600.0

RFM analizi için ilk adım, Güncellik (Recency), Sıklık (Frequency) ve Parasallık (Monetary) olmak üzere üç değişkenin hesaplanmasıdır. Bu aşamada RFM analizi için her müşteriye bir güncellik puanı atanır. Bu puan, müşterinin son işlem tarihine göre hesaplanır ve son işlem değerleri belirli kategorilere ayrılarak oluşturulur. Müşteriler, son işlem tarihlerine göre sıralanır ve en son işlem yapmış olan ilk %20'lik dilimdeki müşterilere 5 skoru verilirken, en uzun süredir işlem yapmamış son %20'lik dilimdeki müşterilere 1 skoru atanır (Park ve diğerleri, 2013).

Sıklık skoru da benzer bir yaklaşımla hesaplanır. Müşteriler işlem sıklığına göre sıralanır, yüksek işlem sıklığına sahip olan müşterilere 5 puan verilirken, düşük işlem sıklığına sahip olanlara 1 puan verilir.

Parasallık skoru, müşterilerin ne kadar harcama yaptığını veya şirketin ürün ve hizmetleri için ne kadar ödeme yaptığı hesaplanır. Müşteriler, yaptıkları harcamalara göre belirli gruplara ayrılır. Yüksek miktarlarda harcama yapan müşteriler, genellikle daha değerli müşteriler olarak kabul edilir ve özel teklifler veya avantajlarla ödüllendirilebilir. En yüksek gelir sağlayan müşterilere yüksek puanlar verilirken, en düşük geliri sağlayanlara 1 puan verilir.

Son olarak, bu üç ayrı skor tek bir değerde birleştirilerek RFM skoru oluşturulur. Bu skor, müşterilerin güncellik, sıklık ve para değerlerini dikkate alarak müşteri segmentasyonu ve pazarlama stratejileri geliştirmek için kullanılır.

Recency, Frequency ve Monetary değerlerinin belirlenmesinde 5'li ölçüm kullanılmıştır. Müşteriler R, F, M değerlerine göre sıralanmış ve %20'lik kategorilere ayrılarak; hangi müşterinin hangi skoru alacağı belirlenmiştir. R, F, M değerlerinin aralıkları Tablo4-4'te sunulmaktadır.

Tablo 4-4: RFM Skor Tablosu

Müşteri Adı	Güncellik	Sıklık	Parasallık	Güncellik Skoru	Sıklık Skoru	Parasallık Skoru
müşteri 1	34.0	66	1779974.35	5	5	5
müşteri 10	761.0	1	36087.49	1	1	3
müşteri 100	800.0	1	28560.0	1	1	3
müşteri 101	81.0	1	369245.0	4	1	5
müşteri 102	341.0	1	3600.0	2	1	1

Tablo4-3'teki veri setimizdeki sayısal değerleri skorlara dönüştürdük. Sayısal değerleri skorlara çevirme işlemi, farklı ölçeklerde bulunan sayısal değerleri anlamlı ve karşılaştırılabilir hale getirmek için kullanılır.

Örneğin, bir müşterinin harcama miktarı binlerce dolar, sıklığı yüzlerce ve son alışveriş tarihi günlerle ifade edilebilir. Bu farklı ölçekler arasında doğrudan karşılaştırma yapmak zordur. Skorlar, tüm metrikleri aynı ölçekte ifade eder ve bu nedenle karşılaştırmaları kolaylaştırır.

Skorlama işlemi, bu sayısal değerleri göreceli olarak sıralayarak, hangi değerin daha büyük veya daha küçük olduğunu daha net bir şekilde görmemizi sağlar. Bu skorlar, her bir gözlem birimini diğerleriyle karşılaştırmamıza yardımcı olur. Örneğin, hangi müşterinin daha yüksek bir parasallık değere sahip olduğunu veya hangi müşterinin daha yakın bir yenilik tarihine sahip olduğunu daha kolay bir şekilde belirlenebilir.

Skorlar, verileri daha anlaşılır hale getirir ve karar verme süreçlerinde rehberlik eder. Sayısal değerler, kendiliğinden anlamlı olmayabilir. Bir müşterinin son alışveriş tarihi 30 gün önce ise, bu bilgiyle müşterinin durumunun ne kadar "iyi" veya "kötü" olduğunu anlamak zor olabilir. Skorlar, bu değerleri bir anlam bağlamında ifade eder ve bu nedenle analizi anlamak daha kolay hale gelir. Özellikle büyük veri setlerinde, her bir müşteriyi bireysel olarak değerlendirmek zor ve zaman alıcı olabilir. Skorlar, hangi müşterilerin daha değerli olduğunu veya daha fazla dikkat gerektirdiğini daha hızlı ve etkili bir şekilde belirlememize yardımcı olur.

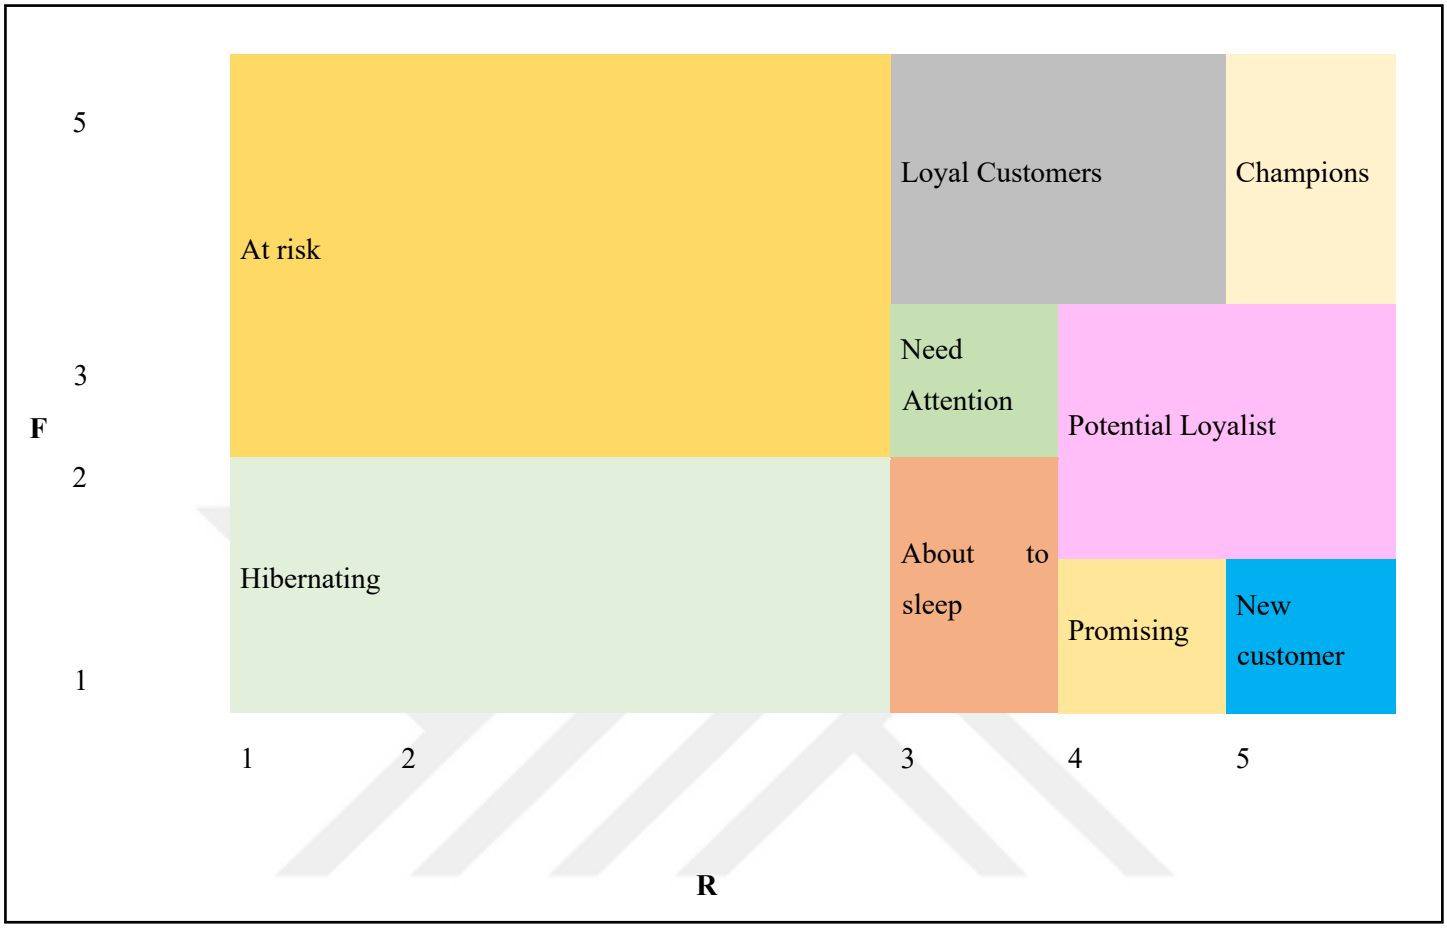
Son aşamada ise bu metrikler kullanılarak RFM skorları oluşturulur. Müşteri davranışlarını daha iyi anlamak ve segmentasyon işlemlerini uygulamak amacıyla, her değişken için özel olarak oluşturulan skorları bir araya getirilir.

Tablo 4-5: RFM Skor Tablosu2

Müşteri Adı	**Güncellik Skoru (R)**	**Sıklık Skoru (F)**	**Parasallık Skoru (M)**	**RFM Skoru**
müşteri 1	5	5	5	555
müşteri 10	1	1	3	113
müşteri 100	1	1	3	113
müşteri 101	4	1	5	415
müşteri 102	2	1	1	211

Tablo4-5'te ilk satır incelendiğinde güncellik skorunun 5, sıklık skorunun 5 ve parasallık skorunun 5 olduğu görülmektedir. Sonrasında her bir parametre skoru birleştirilerek RFM skoru 555 olarak belirlenmiştir. Bu skor üzerinden; müşterinin örneklem ortalamasına göre daha sık işlem gerçekleştirerek; yine ortalamanın üzerinde şirket gelirine katkıda bulunduğu ve çok yakın bir tarihte işlem gerçekleştirmediği sonucu çıkarılmaktadır. Fakat RFM skorlama işleminde her müşterinin az veya çok bir tutarda şirkete kazanç elde ettirdiğini bu nedenle incelenmesi gerek olan skorların R ve F değerleri olduğu belirlenmiştir.

Şekil 4-2: Segment haritası



Segment haritası, bir işletmenin müşteri tabanını anlamak için oluşturulan bir haritadır. Müşteriler belirli özelliklere göre gruplandırılır ve bu segmentlerin özellikleri analiz edilir. Belirli kriterler kullanılarak yapılan bu segmentasyon, işletmelere müşteri ihtiyaçlarını anlama, pazarlama stratejilerini optimize etme ve hedef kitleleri belirleme konularında yardımcı olur. Bu haritalar, işletmelerin rekabet avantajı elde etmelerine ve pazar fırsatlarını değerlendirmelerine olanak tanır.

Şekil4-2 Segment haritasında bulunan bir başka bölümse “can’t loose them” segmentidir. Bu kısım bizim at risk’te bulunan müşterilerimizle benzer özellikleri taşıdıkları için bu iki müşteri grubunu birleştirerek segment sayısı düşürülmüştür.

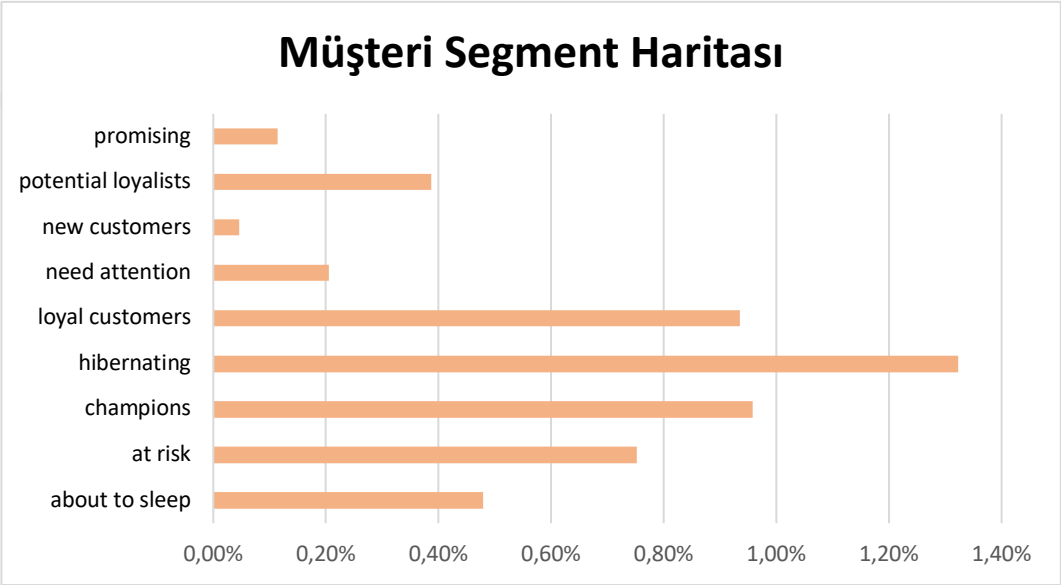
Tablo 4-6: RFM Segment Haritası

	Güncellik			Sıklık			Parasallık		
	Ortalama	**Medyan**	**Toplam**	**Ortalama**	**Medyan**	**Toplam**	**Ortalama**	**Medyan**	**Toplam**
about to sleep	213	209	21	1	1	21	15120	10285	21
at risk	571	569	33	2	2	33	32747	20336	33
champions	29	33	42	33	27	42	784675	307221	42
hibernating	715	710	58	1	1	58	16347	6566	58
loyal customers	123	83	41	12	7	41	211677	82560	41
need attention	224	240	9	2	2	9	99234	20850	9
new customers	29	29	2	1	1	2	23080	23080	2
potential loyalists	63	62	17	2	2	17	114846	21887	17
promising	79	81	5	1	1	5	82302	16254	5

Bu tür analizlerde sadece ortalama değerlere bakmak, bazen yanıltıcı olabilir. Bunun nedeni, uç değerler olarak nitelendirdiğimiz aykırı veriler ortalama değeri önemli ölçüde yukarıya veya aşağıya çekebilmesi ve değişkenin dağılımını etkileyebilmesidir.

Bu nedenle, ortalama ile medyan değerlerini kıyaslayarak aralarındaki farka dikkat etmek daha sağlıklı bir yaklaşım olacaktır. Eğer ortalama değer ve medyan değer arasındaki fark çok büyük değilse, ortalama değerleri kullanmak genellikle güvenilir sonuçlar sağlayacaktır. Medyan, verileri sıraladığınızda ortadaki değeri ifade eder ve aykırı verilere duyarlı değildir, bu nedenle medyan ile ortalama arasındaki fark, veri dağılımının çarpıklığını ve aykırı verilerin etkisini gösterir.

Şekil 4-3: Müşteri Segment Haritası



RFM analizine diğer bir bakış ise her müşteri için RFM verilerine sahip olduğumuz için artık amaç müşteriyi değerlerine göre farklı kategorilere ayırmaktır. Bunun için önce R, F, M değerlerini 1-5 arasındaki değerlere göre ayrılmıştır. 1 en düşük ve 5 en yüksek değeri ifade etmektedir. Burada 5 kategoriye ayırmak için %20, %40, %60 ve %80'lik kesitler alınmıştır. Daha sonra her satır için bu değerleri toplarız ve 3 ile 15 arasında değişen değerlere sahip sütunu 'puan' olarak etiketlenmiştir (Şentürk & Alp, 2023). Ardından %20, %40, %60 ve %80'lik 'skor' kesintileri yaparak müşterileri Bad, Bronze, Silver, Gold ve Platinum olarak kategorize edilmiştir.

Tablo 4-7: RFM Değerlerine göre Etiketlenmiş Müşteri Segmentleri

Güncellik	Sıklık	Parasallık	R	F	M	Skor	RFM Skor	Müşteri Tipi
308	66	1.779.974,35	5	4	5	14	545	platinum
1035	1	36.087,49	1	1	3	5	113	bronze
1074	1	28.560	1	1	3	5	113	bronze
355	1	369.245	4	1	5	10	415	gold
615	1	3600	2	1	1	4	211	bronze

Tablo4-7'de analiz sonucu müşterilerin RFM skorları görülmektedir. Bu skorlar güncellik sıklık ve parasallık değerlerine karşılık gelen skorlardır. Örneğin güncellik 308 değeri R skoru için 5, 66 sıklık F için 4 skorunu ve 1779974,35 TL değeri 5 skorunu vermektedir. Bu değerleri temsil eden bad, bronze, silver, gold ve platinum kategorileri bulunmaktadır.

Tablo 4-8: RFM Analizi Tanımlayıcı İstatistikleri

Müşteri Tipi	**Güncellik**	**Sıklık**	**Parasallık**
Bad	315	1	6.501
Bronze	378	2	18.455,00
Silver	593	3	37.865
Gold	905	8	199.075
Platinum	1346	111	5.884.086

Segmentlerin müşteri tiplerine göre dağılımı tablo 4-9'da gösterilmiştir. Bu dağılımlar her bir müşteri tipine denk gelen yüzdelik dilimi temsil etmektedir.

Tablo 4-9: Segment Dağılımı

Bad	5,70
Silver	18,86
Bronze	37,72
Gold	19,74
Platinum	17,98

- Müşterilerin yaklaşık %18'inin platinum kategorisinde olduğunu ve bunların üç RFM'de de en yüksek sahip müşteriler olduğu görülmüştür.
- Altın kategorisiyle birleştiğinde %38 oranına ulaşan müşteri segmenti, şirketin sadık müşterisini oluşturmaktadır.
- Gümüş kategorisi, işletmenin onlar için teklifler ve yeni stratejiler sunarak onları altın kategorisine dönüştürmeyi hedefleyebileceği kategoridir.
- Bad kategori, işletmeden sık sık alışveriş yapmayan ve en az kar edilen gruptur. Bir süredir alışveriş yapmamış olan harika eski müşterilerdir.

Diğer bir yöntem ve diğer iki yöntemle kıyaslamamızı yapacağımız bir başka yaklaşım, normalizasyon kullanarak kümeleme yapmaktır. Normalizasyon, verilerin [−1,1] veya [0.0, 1.0] gibi daha küçük ya da ortak bir aralığa düşecek şekilde dönüştürülmesini içermektedir. Veri setini normalleştirmek için tüm niteliklere eşit ağırlıklar verilmeye çalışılmaktadır. Normalizayon, özellikle sınıflandırma algoritmalarında yaygın olarak kullanılmaktadır. (Han, Kamber, & Pei, Data Mining Concepts and Techniques , 2012)

MIN-MAX yöntemine dayalı olarak ve (1) numaralı formül kullanılarak endeksler, modelleme aşamasına hazırlık yapmak amacıyla sıfır ile bir aralığında normalize edilir. Bu formüllerde, MAXr, MAXf ve MAXm en yüksek değeri temsil ederken, MINr, MINf ve MINm veri kümesindeki en düşük değeri temsil eder, sonunda R, F, M', son değerlere normalize edilir.

$$R' = \frac{(R - MIN_R)}{(MAX_R - MIN_R)} \quad M' = \frac{(M - MIN_M)}{(MAX_M - MIN_M)} \quad F' = \frac{(F - MIN_F)}{(MAX_F - MIN_F)} \tag{1}$$

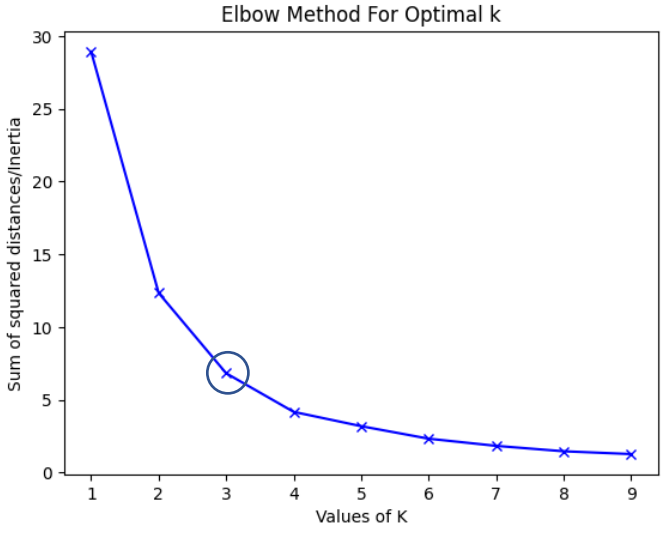
Kümeleme yöntemi, müşteri segmentasyonu için kullanılmaktadır. RFM parametreleri kümeleme işlemine dahil edilir. Müşterileri segmentlemek için K-ortalama kümeleme kullanılmıştır. K-ortalama kümeleme tekniğinde, küme sayısı karar verici tarafından belirlenmelidir. Optimal k değerini belirlemek için çeşitli metrikler kullanılabilir. Bu çalışmada, denklem (2)'de tanımlanan DUNN endekslerinden biri kullanılmıştır.

$$D_{ij} = \frac{\max(dist\ in\ Ci)}{dist\ Ci,Cj} \quad , \quad i \neq j \quad ve \quad 1 \leq i,j, \leq k \tag{2}$$

k, her bir kümelemedeki küme sayısını temsil eder. Ci ve Cj, kümelemeleri ifade eder; max dist Ci, Ci içindeki ortalamanın diğer nesnelerle olan maksimum mesafe aralığıdır; dist Ci, Cj ise Ci ve Cj'nin ortalama arasındaki mesafeyi gösterir.

Her bir k kümesi için denklem (2), o kümeler içindeki her çift küme için k*(k-1) kez hesaplanmalıdır, çünkü bu işlem her bir kümeye özgüdür. Ardından, bu hesaplamaların maksimumu diğer kümelemenin maksimumu ile karşılaştırılır ve sonunda maksimum dij'nin en düşük olduğu kümeleme, en iyi kümeleme olarak seçilir.

Şekil 4-4: RFM Küme Grafiği



Şekil4-4 küme sayısı ile veriye ait karesel hata oranı arasındaki ilişkiyi gösteren bir grafik sunmaktadır. Grafikte gözlemlendiği üzere, küme sayısı arttıkça toplam karesel hata oranı hızla azalmaktadır ve bu düşüş 3 küme sayısına kadar devam etmektedir. Ancak 3'ten sonra, hata oranındaki değişim yavaşlamakta ve grafik yatay bir seyir almaya başlamaktadır.

Bu noktada, 3 küme sayısının bu veri seti için optimal küme sayısı olduğu görülmektedir. Bu seçim, hem hata oranının kabul edilebilir bir seviyede düşük olduğu anlamına gelir, hem de daha fazla küme eklemenin modelin anlaşılabilirliğini zorlaştırabileceği bir aşamada durulduğunu gösterir. Dolayısıyla, bu analiz sonucunda 3 küme sayısının tercih edilmesi, veri kümesinin etkili bir şekilde kümelendiği ve analizin sonuçlarının anlamının korunduğu anlamına gelmektedir.

Tablo 4-10: RFM Skor Kümeleri

Kümeler	R Ortalama	F Ortalama	M Ortalama	RFM Skorları
1	0,7149	0,0051	0,0044	R ↑F ↓M ↓
2	0,1436	0,4444	0,0191	R ↓F ↑M ↓
3	0,0188	0,5431	0,2876	R ↓F ↑M ↑
Ortalama Değer	0,2920	0,3308	0,0960	

K-ortalamalar metodu sonucunda oluşan kümeler Tablo4-10'da gösterilmiştir. Tablodaki verilere göre, birinci kümenin R değeri ($\bar{X}$ =0,7149), F değeri ($\bar{X}$ =0,0051) ve M değeri ($\bar{X}$ =0,0044) ortalama (F, M) değerlerinin üstündedir ve küme "R ↑F ↓M ↓olarak adlandırılmıştır. Bu kümede bulunan müşteriler örneklem ortalamasına göre düşük sıklıkta işlem gerçekleştirdikleri ve harcama miktarlarının düşük olduğu görülmektedir. Bu kümeye dahil olan müşteriler araştırmaya dahil ettiğimiz sektörde genellikle ihale usulü satın alma yaparak şirketten tek seferlik alışverişler yapan müşterilere ait verileri oluşturmaktadır. Bu müşteriler "Yeni Müşteri" olarak tanımlanmaktadır.

İkinci kümenin F değeri ($\bar{X}$ = 0,4444) ortalama R değeri ($\bar{X}$ = 0,1436) ve M ($\bar{X}$ 0,0191) değerinin üzerindedir ve küme "R ↓F ↑M ↓" olarak adlandırılmıştır. Bu kümede bulunan müşteriler bir yıllık tarih periyodunda örneklem ortalamasına göre daha fazla işlem gerçekleştirmiş olsalar da yüksek harcamaları bulunmamaktadır. "R ↓F ↑M ↓" kümesindeki müşteriler "Hareketli Düşük Harcamalı Müşteriler" veya "Uyuyan Müşteri" olarak tanımlanmıştır. Bu müşterileri yine sektör bazında belli hastalık veya konu üzerinde araştırmayı yapan ve araştırmanın devamlılığı olan müşterilerdir.

Üçüncü kümenin R değeri ($\bar{X}$ = 0,0188) ve M değeri ($\bar{X}$ =4.06) ortalama R ve M değerlerinin üstünde olmasına rağmen F değeri ($\bar{X}$ =1,53) ortalama değerinin altındadır ve küme "R ↓F ↑M ↑" olarak adlandırılmıştır. R ↓F ↑M ↑ kümesinde yer alan müşterilerin yakın zamanda yüksek harcama yapan müşterileri barındırıyor olması muhtemeldir. R ↓F ↑M ↑ kümesindeki müşteriler "Yüksek Potansiyel Barındıran Müşteriler" olarak tanımlanmıştır. Bu müşteriler, son zamanlarda işlem yapmamış olabilirler. Yani son alışverişleri biraz zaman önce gerçekleşmiştir. (Shih & Liu, 2003)

Tablo 4-11 Müşteri Profilleri

Müşteri Profili	Müşteri	Pazarlama Stratejisi
Yeni Müşteri	64	Şirkette en son işlem yapma tarihi en yakın olan müşteriler, genellikle "en yeni müşteriler" olarak kabul edilir. Bu müşteriler için çeşitli "yeni müşteri kazanma" programları düzenlenmelidir. Bu programlar, müşterilere aşamalı bir şekilde biyoteknolojik ürünleri, hizmetleri ve uygulamaları hakkında bilgi verilmesini ve çapraz satış ile farklı ürünlerin kullanımının teşvik edilmesini amaçlamaktadır. Webinarlar düzenlenebilir. Bu programlar, yeni müşterilerin firmamızın sunduğu fırsatları daha iyi anlamalarına yardımcı olabilir. Müşterilere, firmanın farklı hizmetleri hakkında bilgi sunularak ihtiyaçlarına uygun ürün ve hizmetlerin nasıl kullanılacağı anlatılmalıdır. Ayrıca, çapraz satış ile müşterilerin birden fazla firma ürününe sahip olmaları teşvik edilmelidir. Bu, hem müşterilere daha fazla değer sunabilir hem de banka için gelir artışı sağlayabilir.
Yüksek Potansiyel Barındıran Müşteri	144	Bu müşteriler, yakın zamanda şirkete yüksek gelir sağlamış olmalarına rağmen aylık işlem sıklıkları, örneklem ortalamasının altında bulunmaktadır. Bu müşteriler sektör bazında belli hastalık veya konu üzerinde araştırma yapan kişilerden oluşmaktadır. Bu durumda müşteri ilişkilerini güçlendirmek ve bu müşterilerin işlem sıklıklarını artırmak için fırsatlar sunulmalıdır. Bu ürünlerin tanıtılması, müşterilere şirketin sunduğu çevrimiçi hizmetler, otomatik ödeme seçenekleri ve sigorta ürünleri hakkında bilgi verilmesini içerebilir. Müşterilere bu ürünlerin faydaları ve kullanımları konusunda detaylı açıklamalar sunularak, onların bu hizmetleri nasıl kullanabileceklerini anlamalarına yardımcı olunmalıdır.

Uyuyan Müşteri	20	Bu gruptaki müşteriler, uzun bir süredir aktif olarak işlem yapmamışlardır. Bu müşteriler tek seferlik ihale üzeri satın alma gerçekleştirmiş olabilirler. Bu müşteri grubu için, kişilerin ayrılma nedenlerine bağlı olarak özelleştirilmiş tutundurma faaliyetleri gerçekleştirilmelidir.

4.4.2 RFMV (Recency-Frequency-Monetary-Variety) Analizi

RFM-V analizi, yüksek harcama oranlarına sahip müşterileri tanımlamak için kritik bir analiz aracı olacaktır. Bu analiz yöntemi, stok yönetimi ve promosyon faaliyetlerine önemli katkılarda bulunacaktır. RFM modeline göre benzer profillere sahip müşteriler, ürün çeşitliliği açısından farklı özelliklere sahip olabilir. Bu analiz sayesinde, bu farklılıkları dikkate alarak müşteri segmentasyonu yapmak mümkün olacaktır.

Tablo 4-12: RFMV Modelindeki Değişken Tanımları

Başlangıç Verileri	Dönüştürülmüş Veri
Son satın alma tarihi	Güncellik (R)
Satın alma sayısı	Sıklık **(S)**
Harcanan toplam tutar	Parasallık **(M)**
Satın alınan ürün sayısı	Çeşitlilik **(V)**

R, F, M ve V için tanımlayıcı istatistikler Tablo4-12'de verilir. V değişkeni, bir müşterinin satın aldığı farklı ürün sayısını tanımlar.

Tablo 4-13: RFMV Modelindeki İstatistikler

	Güncellik	**Sıklık**	**Parasallık**	**Çeşitlilik**
Kişi sayısı	228	228	228	228
Ortalama	601,58	9	216380	28
Standart Sapma	317,18	18	575700	63
Minimum	293	1	100	1
25%	327,75	1	8744,375	2
50%	491	2	27944,5	45051
75%	813	7	91153,22	18.25
Maksimum	1346	111	5884086,75	348

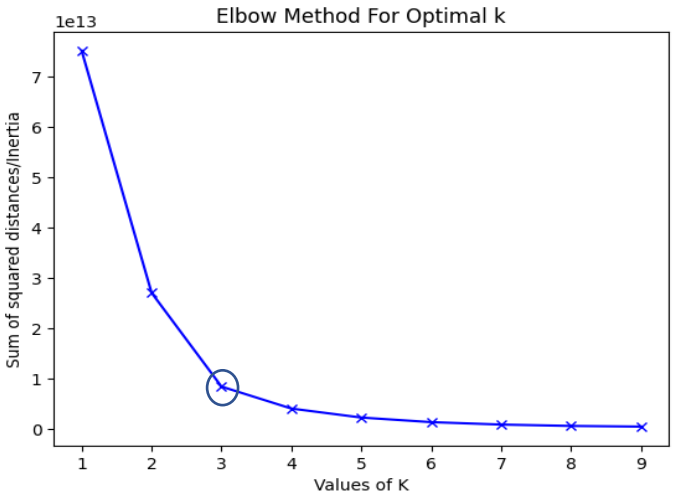
Güncellik (R) için maksimum ve minimum değerler sırasıyla 293 ve 1346 arasında değişmektedir. Veriler ters kodlandığı için, daha yüksek değerler müşterinin pazara son zamanlarda ziyaret ettiğini göstermektedir.

Frekans (F) için ise maksimum ve minimum değerler 1 ile 111 arasında bulunmaktadır. Ortalama frekans ise 9'dur. Harcama miktarı (M) maksimumda 5.884.086,75 TL'ye kadar çıkabilirken, ortalama harcama 216.380 TL'dir.

Maksimum ürün çeşitliliği 348 farklı ürün sunulurken, minimum çeşitlilik 1'dir, ki bu da beklenen bir durumdur. Bu değerler incelenip şirketin genel verileri göz önünde bulundurulmuştur.

Bu aşamada kümeleme algoritmalarından biri olan K-ortalama algoritması kullanılmıştır. K-ortalama algoritması, ön tanımlı olması gereken küme sayısına dayanan bölüm kümeleme prensibine dayanmaktadır. Ardından, başlangıç küme sayısına bağlı olarak veriler farklı kümelerde gruplandırılır. Bu algoritmanın temel zorluklarından biri ise optimal küme sayısını belirlemektir.

Şekil 4-5: RFMV Küme Grafiği



Küme sayısı arttıkça, varyans (grup içi kareler toplamı) azalır. Dirsek noktası, küme sayısını azaltma ve her küme içindeki varyansı azaltma arasında en uygun dengeyi temsil eder. Bu nedenle üç kümeye karar verilmiştir. Bu, modelin karmaşıklığının (yani küme sayısının) arttıkça, modelin çıktısının belirgin bir şekilde iyileşmediği anlamına gelir. Sonuç olarak, müşteriler R, F, M ve V değerlerine dayalı olarak üç farklı kümeye ayrılmıştır.

Tablo4-14'te üç kümeye ayrılan müşteri sayısı ve ortalama RFM-V değerleri verilmiştir. Birinci küpte 143 müşteri bulunmaktadır. Bu müşterilerin güncellik ortalaması 436, frekans ortalaması 6 ve harcama ortalaması 118.461 TL'dir. Ortalama olarak 16 farklı ürün satın almışlardır. İkinci kümede ise 67 müşteri bulunmaktadır. Bu kümeye ait ortalama güncellik değeri 1032, ortalama çeşitlilik ise 4'tür. En az alışveriş yapan müşteriler bu kümeye dahildir.

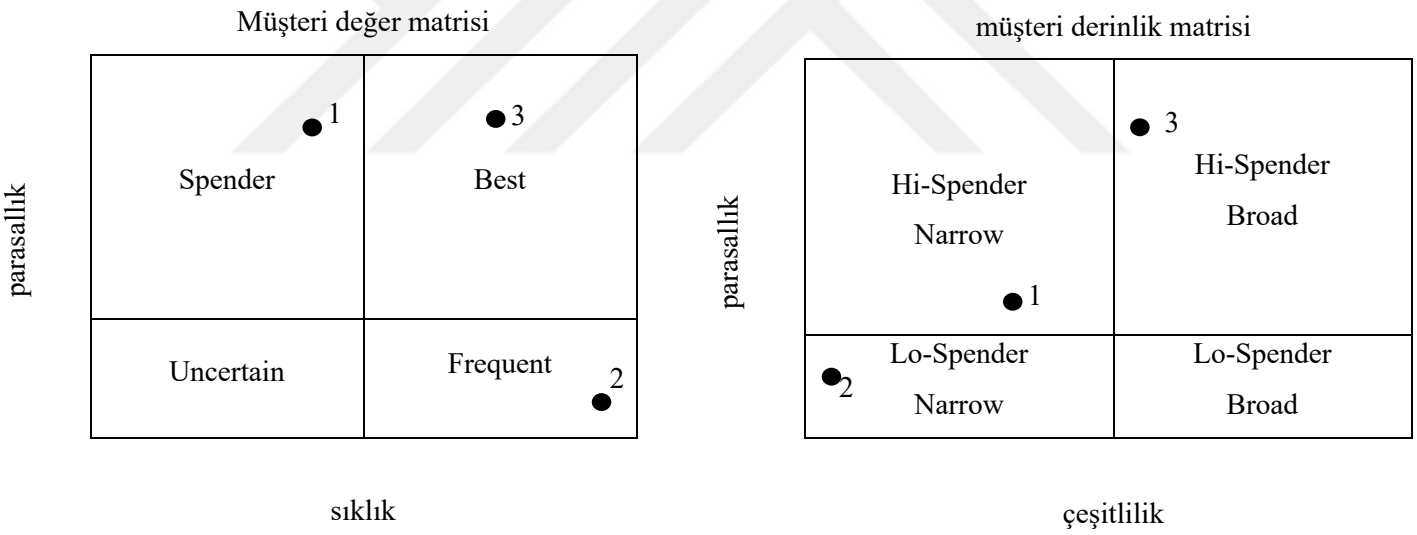
Üçüncü kümede sadece 18 müşteri bulunmaktadır, ancak bu tüm kümeler arasında en fazla çeşitliliği en yüksek ve en sık harcama yapan müşterilere sahiptir. (M = 1.705.050 TL)

Tablo 4-14 Ortalama RFMV Değerleri

Kümeler	R Ortalama	F Ortalama	M Ortalama	V Ortalama	Müşteri Sayısı
1	436	6	118.461	16	143
2	1032	1	25.430	4	67
3	314	59	1.705.050	215	18

Bu küme istatistiklerine dayalı olarak, Müşteri Değer Matrisi ve Müşteri-Ürün Derinlik Matrisi Şekil4'te oluşturulmuştur. Küme tabanlı değerlendirmeler Tablo4-14'te verilmiştir. Bu küme istatistiklerine dayanarak, Müşteri Değer Matrisi ve Müşteri-Ürün Derinliği Matrisi Şekil4'te oluşturulur. Tablo4-14'te, küme tabanlı değerlendirmeler sunulmaktadır. 3.küme gruplar arasında en iyi ve yüksek harcayıcı geniş grupta bulunmaktadır (Marcus, 1998).

Şekil 4-6: Müşteri Değer Matrisi ve Müşteri Ürün Derinlik Matrisi



1. Küme belirsiz ve düşük harcayıcılarla sınıflandırılan bir dar grupta bulunmaktadır. Bu müşterilere büyüme potansiyeli müşterileri adı verilebilir. Bu müşterilere sağ üst (ikinci) dörtlüğe taşımak için yukarı satış yapmak için çaba göstermelidir.

2. Küme yüksek harcayıcıların bulunduğu dar bir grupta yer almaktadır. Yüksek miktarlarda harcarlar, ancak nadiren gelirler ve sınırlı ürün çeşitliliği satın alırlar. Bu küme en iyi müşteriler olarak adlandırılabilir. Bu müşterilerle ilişkiler geliştirilmeli ve ürün çeşitliliği artırılmalıdır.

3. Küme ikinci dörtgen içinde bulunan müşterilere "yüksek harcama yapan geniş" adı verilir. Onlar işletmenin en derin müşterileridir. Hem harcama miktarı hem de bu müşterilerin satın aldığı ürün çeşitliliği yüksektir. Onları sürdürmek için önleyici pazarlama stratejileri önerilir. (Marcus, A Practical Yet Meaningful Approach to Customer Segmentation, 1998)

Tablo 4-15: RFMV Kümeleri

Küme	Değer	Derinlik	Müşteri Profili
1	Spender	Hi-Spender Narrow	Büyüme Potansiyelli Müşteri
2	Frequent	Lo-Spender Narrow	Potansiyel Müşteri
3	Best	Hi Spender Narrow	Yüksek değer ve sadakat

Önerilen RFM-V yöntemi ve müşteri-ürün derinlik matrisi, perakendecinin müşterilerin derinliğine odaklanmasını ve müşterileri matrislerde istenen dörtgenlere taşımak için adımlar atmasını sağlar. RFM, müşteri ilişkileri yönetimi alanında kullanılan etkili bir analiz yöntemidir ve müşterileri tüketim alışkanlıklarına göre gruplandırarak işletmeler için değerli bilgiler sağlar. Harcama aralığı, sıklığı ve miktarı gibi RFM değerleri üzerinden müşteriler, farklı kategorilere ayrılabilir ve bu gruplara göre özelleştirilmiş pazarlama stratejileri geliştirilebilir. Bu sayede işletmeler, karlı müşterileri, tek seferlik müşterileri, belirsiz müşterileri, düzenli müşterileri ve daha fazlasını tanımlayabilir. Ancak RFM analizi, ilişkileri derinleştirme aşamasında tam bir çerçeve sunamayabilir. Özellikle ürün çeşitliliği ve miktarı gibi önemli faktörler göz ardı edildiğinde, müşterilerle daha etkili ilişkiler kurma konusundaki zorluklar ortaya çıkabilir.

Bu temel soruna çözüm olarak, araştırmacılar, müşteri segmentasyonu için genişletilmiş bir RFM modeli önermektedir. Bu model, müşterilerin satın aldıkları ürünlerin çeşitliliğini V parametresi olarak içerir. Bu sayede, RFMV analizi ile işletmeler hem müşterileri hem de satın aldıkları ürünleri daha ayrıntılı bir şekilde inceleyebilirler. Özellikle süpermarket gibi çok sayıda ürün türü sunan işletmeler için, bu modelin pazarlama, satış ve tedarik zinciri süreçlerini daha iyi entegre etme ve verimlilik artırma potansiyeli olduğu düşünülmektedir.

Araştırmacılar ayrıca müşteri gruplarını miktar ve çeşitlilik açısından analiz etmek için "müşteri-Pazar derinlik matrisi" adını verdikleri bir model önermektedir. Bu matris, müşteri kümelerini dört farklı dörtgen içine yerleştirir ve her bir kümeye özgü pazarlama ve satış stratejilerinin uygulanmasını önerir. V parametresi, müşterilerin satın aldıkları ürünlerin eğilimlerini izleme konusunda önemli bir araçtır. Analiz sonuçları, daha etkili pazarlama stratejileri geliştirmek ve etkili promosyon önerileri sunmak için sepet analizi verileri ile ilişkilendirilebilir.

Yukarıda, RFMV analizi ile ilgili verilerin normalizasyon uygulanmamış halindeki ham veriler üzerinden segmentasyonunun yapıldığı belirtilmiştir. Her bir kümenin değerlendirmesi yapılarak uygun pazarlama stratejileri belirlenmiştir. Aynı veri seti üzerinde normalizasyon işlemi gerçekleştirilerek kümelere ayrılmıştır. Oluşan kümeler, Tablo4-16'da gösterildiği gibi değerlendirilmiştir.

Tablo 4-16: RFMV Küme Ortalamaları

Kümeler	R Ortalama	F Ortalama	M Ortalama	V Ortalama
1	0,1358	0,0537	0,2011	0,0436
2	0,7018	0,005	0,0043	0,0096
3	0,0203	0,5318	0,2897	0,6239
Ortalama`	0,286	0,1968	0,165	0,2257

Küme 1: **R ↓F ↓ M ↑ V ↓**

Küme 1'deki müşteri grubu, RFV değerleri ortalama altında olmasına rağmen M değeri ortalamanın üzerindedir. Bu durum, bu müşteri grubunun şirkete harcama yapmış ancak henüz sık alışveriş yapmamış potansiyel müşteriler olduğunu göstermektedir. Bu müşterilere özel kampanya teklifleri, bilgilendirme ve kişiselleştirme ile RFV değerlerini artırmak mümkündür. Öncelikle, özel kampanyalar ve tekliflerle, satın alma motivasyonlarını yükselterek bu müşterilerin tekrar şirkete yönlendirilmesi sağlanabilir. RFMV analizi kullanılarak, müşterilerin daha önce aldıkları ürünler göz önüne alınarak özel kampanyalar düzenlenebilir ve bu ürünler üzerinden devam edilebilir. Bilgilendirme için ise MİY sistemi altyapısındaki müşteri listesine özel bilgi afişleri ile e-posta gönderimi yapılabilir. Ayrıca, online eğitim ve webinar gibi etkinliklerle müşterilere şirketin sunduğu hizmetler hakkında detaylı bilgiler verilebilir.

Son olarak, müşteri altyapısındaki bilgiler kullanılarak, kullanılan çalışmalara uygun ürünler sunulabilir ve özel jestlerle ilişkiler güçlendirilebilir. Bu yaklaşımlar, bu müşteri grubunu şirkete daha fazla çekmek ve alışveriş sıklıklarını artırmak için etkili bir strateji olabilir.

Küme 2: R ↑F ↓M ↓ V ↓

Şirketimiz, biyoteknoloji sektöründe satışa sunduğu ürünlerle ilgili potansiyel müşterilere bilgi sağlamak amacıyla çeşitli stratejiler uygulamaktadır. İlk olarak, satılan biyoteknoloji ürünleri hakkında detaylı bilgiler sunarak, müşterilere ürünlerin özellikleri ve avantajları konusunda açıklamalarda bulunmaktayız. Ayrıca, benzer ürünleri sunan diğer şirketlerin kit içerikleriyle karşılaştırmalı tablolar veya rehberler sunarak, potansiyel müşterilere daha bilinçli kararlar vermelerine yardımcı olmaktayız. Bu bilinçlendirme sürecinde, müşterinin ilk alımının sebebini anlamak da önemlidir. Alınan ürünün bir ihale, hastalık tanısı veya doktora çalışmalarına yönelik olup olmadığını belirleyerek, müşterilere özel teşvikler sunabiliriz. Bu teşvikler arasında özel indirimler, ücretsiz kargo veya hoş geldin indirimleri gibi avantajlar yer almaktadır. Bu stratejilerle potansiyel müşterileri etkilemeyi ve şirketimize çekmeyi hedeflemekteyiz.

Küme 3: R ↓F ↑M ↑V ↑

Şirketin bu kümede yer alan müşterileri, genellikle farklı ürünleri yüksek miktarlarda satın alırken, son satın alma tarihinden bu yana bir süre geçmiştir. Bu müşterileri tekrar kazanmak için özel ayrıcalıklar sunulabilir, bu da yüksek değerli indirimler, yapılan kongrelere davetlerle ve çalışmalarına uygun ürün önerilerini içerebilir. Ayrıca, düzenli iletişim kurularak müşteri sadakatini artırmak, özel güncellemeler ve yüksek müşteri hizmetleri ile değerli müşterilere özel bir deneyim sunmak da önemlidir. Bu stratejiler, müşteri bağlılığını güçlendirerek şirketin genel başarısına katkıda bulunabilir.

Biyoteknoloji sektöründe faaliyet gösteren işletmeler için başarılı bir pazarlama stratejisi oluşturmak, müşteri davranışlarına ve sektör özelindeki ihtiyaçlara odaklanmayı gerektirir. Bu bağlamda, analitik araçları kullanarak müşteri davranışları ve tercihleri hakkında detaylı veri toplama, şirketlerin pazarlama stratejilerini daha etkili hale getirmelerine olanak tanır. Bu veriler, müşteri segmentasyonunu daha doğru bir şekilde yapmayı, özelleştirilmiş kampanyalar geliştirmeyi ve müşteri memnuniyetini artırmayı destekleyebilir. Ayrıca, biyoteknoloji sektörü dinamik bir alan olduğundan, işletmelerin stratejilerini sektöre özgü ihtiyaçlara adapte etmeleri önemlidir. Yeni ürün lansmanları, sektörel yenilikler ve müşteri eğilimleri gibi faktörler göz önünde bulundurularak stratejiler geliştirilmelidir. Müşterilerin sektöre özgü beklentilerini anlamak ve bu beklentilere uygun ürün ve hizmetler sunmak, işletmenin rekabet avantajını artırabilir.

4.4.2.1 LRFM (Length-Recency-Frequency-Monetary) Analizi

Biyoteknoloji sektörü üzerine yaptığımız araştırmada RFM modeline ek bir değişken olarak uzunluk (L) değişkenin eklenmiş olduğu, müşteri ilişkisi modeli olarak dört temel boyuttan oluşan LRFM modeli ele alındı: ilişki süresi (L), son işlem zamanı (R), alış sıklığı (F) ve maddi değer (M). Bu dört boyut kullanılarak müşterileri kümelendirmek ve farklı kümelerin müşteri yaşam değeri (CLV) analizini yapmak ve hesaplamak için bu yaklaşım kullanıldı. Daha sonra, benzer CLV'ye sahip kümeleri birleştirerek özel bir kümeyi oluşturmak için bu analiz sonuçları kullanıldı. Son olarak, bu kümeleri CLV puanlarına göre sıralamak amacıyla bir değerlendirme yapıldı.

Tablo 4-17 LRFM Modelindeki Değişken Tanımları

Başlangıç Verileri	Dönüştürülmüş Veri
Son satın alma tarihi	Güncellik
Satın alma sayısı	Sıklık
Harcanan toplam tutar	Parasallık
İlk ziyaret ile son ziyaret arasındaki süre	Uzunluk

İlk adımda, her müşteri için L, R, F, M değerleri gerçek değerler kullanılarak hesaplanır. L, R, F, M için tanımlayıcı istatistikler Tablo4-18'de verilmiştir. L değişkeni, bir müşterinin ilk ziyaret ile son ziyaret arasındaki süre tanımlanır.

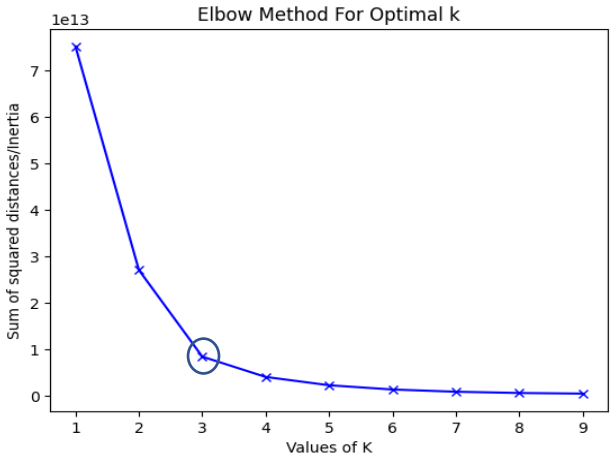
Tablo 4-18: LRFM Modelindeki İstatistikler

	Güncellik	**Sıklık**	**Parasallık**	**Uzunluk**
Müşteri Sayısı	228	228	228	228
Ortalama	601,58	9	216.380	350
Standart Sapma	317,18	18	575700	400
Minimum	293	1	100	0
25%	327,75	1	8.744,375	0
50%	491	2	27.944,5	165
75%	813	7	91.153,22	710
Maksimum	1346	111	5.884.086,75	1069

Güncellik (R) için maksimum ve minimum değerler sırasıyla 293 ve 1346 arasında değişmektedir. Veriler ters kodlandığı için, daha yüksek değerler müşterinin pazara son zamanlarda ziyaret ettiğini göstermektedir. Frekans (F) için ise maksimum ve minimum değerler 1 ile 111 arasında bulunmaktadır. Ortalama frekans ise 9'dur.

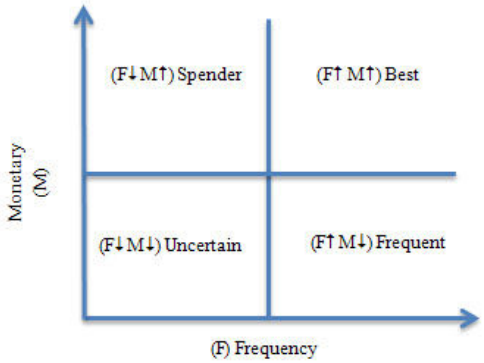
Harcama miktarı (M) maksimumda 5.884.086,75 TL'ye kadar çıkabilirken, ortalama harcama 216.380 TL'dir. Maksimum geçen süre 1069 günken , minimum geçen süre 0'dır.

Şekil 4-7: LRFM Küme Grafiği



Müşteriler L, R, F ve M değerlerine dayalı olarak üç farklı kümeye ayrılmıştır. Üç kümeye ayrılan müşteri sayısı ve ortalama LRFM değerleri verilmiştir. Marcus (1998), müşteri değer matrisi olarak adlandırdığı bir matris önerir ki bu, Şekil4-8'de gösterilir; bu matris, müşteri alışveriş sıklığı (F) ve parasal değer (M) olarak iki ekseni kullanır. İki diğer gösterge müşteri ilişki süresi (L) ve müşteri son işlem zamanı (R) ve bu göstergeler müşteri sadakati ile ilişkilidir. Bu nedenle bu matris, müşteri sadakat matrisi olarak tanımlanır. (Marcus,1998)

Şekil 4-8: Müşteri Sadakat Matrisi



Sung ve Sang'ın (1998) müşteri segment açıklamasına atıfta bulunuyor ve grupların ortalaması genel ortalama değerinden büyükse yukarı sembolünü (↑), küçükse ise aşağı sembolünü (↓) kullanıyor. Chang ve Tsay (2004) daha da ileri giderek 16 grup toplamını beş tür müşteri grubuna toplamayı öneriyor, Şekil 3'te gösterildiği gibi: (1) Çekirdek müşteriler: yüksek değerli sadık müşterileri içerir(LRFM ↑ ↓ ↑ ↑); yüksek sıklıkta alışveriş yapan müşterileri içerir ve platin müşterileri içerir

(LRFM ↑ ↓ ↑ ↓), (2) Potansiyel müşteriler: potansiyel sadık müşterileri içerir (LRFM ↑ ↑ ↓ ↑ ↑), potansiyel yüksek frekanslı müşterileri içerir (LRFM ↑ ↑ ↑ ↓) ve potansiyel tüketim müşterilerini içerir (LRFM ↑ ↑ ↓ ↑); (3) Kayıp müşteriler: yüksek değerli kayıp müşterileri içerir (LRFM ↓ ↑ ↑ ↑), sıklıkla kaybolan müşterileri içerir (LRFM ↓ ↑ ↑ ↓), tüketim kaybolan müşterileri içerir (LRFM ↓ ↑ ↓ ↑) ve belirsiz kayıp müşterileri içerir (LRFM ↓ ↑ ↓ ↓); (4) Yeni müşteri grupları: yüksek değerli yeni müşterileri içerir (LRFM ↓ ↓ ↑ ↑), sıklıkla promosyon yapan müşterileri içerir (LRFM ↓ ↓ ↑ ↓), harcama yapan müşterileri içerir (LRFM ↓ ↓ ↓ ↑) ve belirsiz yeni müşterileri içerir (LRFM ↓ ↓ ↓ ↓); (5) Tüketim kaynaklı müşteriler: düşük tüketim maliyetli müşterileri içerir (LRFM ↑ ↓ ↓ ↓), yüksek tüketim maliyetli müşterileri içerir (LRFM ↑ ↑ ↓ ↓). (Alvandi M., 2012)

MIN-MAX yöntemine dayalı olarak ve (3) numaralı formül kullanılarak endeksler, modelleme aşamasına hazırlık yapmak amacıyla sıfır ile bir aralığında normalize edilir. Bu formüllerde, MAXr, MAXf MAXm ve MAXl en yüksek değeri temsil ederken, MINr, MINf , MINm ve MINl veri kümesindeki en düşük değeri temsil eder, sonunda L, R, F, M son değerlere normalize edilir.

$$R' = \frac{(R - MIN_R)}{(MAX_R - MIN_R)} \quad M' = \frac{(M - MIN_M)}{(MAX_M - MIN_M)} \quad F' = \frac{(F - MIN_F)}{(MAX_F - MIN_F)}$$

$$L' = \frac{(L - MIN_L)}{(MAX_L - MIN_L)}$$

Tablo 4-19: LRFM Skor Kümeleri

Kümeler	L Ortalama	R Ortalama	F Ortalama	M Ortalama	LRFM Skorları	Müşteri Sayısı
1	0,4740	0,7274	0,0047	0,0045	L ↓R ↑F ↓M ↓	61
2	0,8685	0,0377	0,2446	0,1064	L ↑R ↓F ↑M ↑	65
3	0,1514	0,1960	0,0137	0,0115	L ↓R ↓F ↓M ↓	102
Ortalama	0,4979	0,3203	0,0876	0,0408		

K-ortalamalar metodu sonucunda oluşan kümeler Tablo4-19'da gösterilmiştir. Tablodaki verilere göre, birinci kümenin R değeri ($\bar{X}$ =0,7274), F değeri ($\bar{X}$ =0,0047), M değeri ($\bar{X}$ =0,0045) ve L ($\bar{X}$ =0,4740) ortalama (L, R, F, M) değerlerinin altındadır ve 1. Kümede yer almaktadır. Bu kümede bulunan müşteriler potansiyel müşteri tabanındaki belli bir kategoriyi ifade eder. Bu kategori, işletmenin hedef kitlesi içinde yer alabilecek, ancak henüz bir işlem gerçekleştirmemiş veya belirli bir dönemde etkileşime girmemiş kişileri kapsar.

Biyoteknoloji sektöründe özel ve devlet üniversitelerine yönelik laboratuvarlara yapılan satışlarda daha etkili olabilmek için şu öneriler göz önünde bulundurulabilir. Üniversitelerin laboratuvarlarına yönelik özel eğitim ve danışmanlık hizmetleri sunarak, ürünlerin etkili ve verimli bir şekilde kullanılmasına destek olabilirsiniz. Üniversite personeline özel eğitim seminerleri veya online eğitim programları düzenleyerek, ürünlerin doğru ve verimli bir şekilde kullanımını sağlamak amacıyla iş birliğini güçlendirebilirsiniz.

Üniversite laboratuvarları ile ortak araştırma ve geliştirme projelerine katılarak, yeni ürünlerin geliştirilmesi veya mevcut ürünlerin iyileştirilmesi için iş birlikleri kurabilirsiniz. Bu tür iş birlikleri hem ürün kalitesini artırabilir hem de üniversitelerle uzun vadeli iş ilişkileri oluşturarak müşteri sadakatini güçlendirebilir. Laboratuvarlara yönelik özel indirimler veya toplu alım teşvikleri sunarak, üniversitelerin bütçe kısıtlamalarını hafifletebilir ve iş birliğini artırabilirsiniz. Toplu alım anlaşmaları veya belirli bir miktarın üzerindeki alımlara özel avantajlar sağlamak, üniversitelerin sizi tercih etmelerini teşvik edebilir. Ürünlerinizi deneme ve değerlendirme imkanı sunarak, laboratuvarlarda ürünlerin etkili kullanımını göstererek güven oluşturabilirsiniz. Ürün demoları ve deneme imkanları, üniversite personelinin ürünlerin avantajlarını daha yakından görmelerine olanak tanır.

Laboratuvarların ihtiyaçlarına yönelik çözümler ve ürün adaptasyonları sunarak, onların spesifik gereksinimlerini karşılayabilir ve müşteri memnuniyetini artırabilirsiniz. Ürünlerin laboratuvar şartlarına uygunluğunu vurgulayarak, üniversiteleri daha fazla çekici kılabilirsiniz. Bu öneriler, biyoteknoloji ürünlerini özel ve devlet üniversitelerine yönelik satışlarda daha etkili hale getirmenize yardımcı olabilir.

"(L ↓R ↑F ↓M ↓)" kümesindeki müşteriler "belirsiz kayıp müşterileri içerir. Kümenin R değeri ($\overline{X}$ = 0,0377) ortalama F değeri ($\overline{X}$ = 0,1436), M ($\overline{X}$ 0,0191) ve L ($\overline{X}$ = 0,8685) değerinin altındadır ve küme "(LRFM ↑ ↓ ↑ ↑);" olarak adlandırılmıştır. Bu kümede bulunan müşteriler işletme için özel bir değer taşıyan ve uzun vadeli olarak sadakat gösteren müşterileri tanımlar. Bu müşteriler, işletmenin gelirini artıran ve düzenli olarak ürün veya hizmet satın alan kişilerdir. "(LRFM ↑ ↓ ↑ ↑);" kümesindeki müşteriler "yüksek değerli sadık müşteriler olarak tanımlanmıştır. Bu müşterileri işletme için uzun vadeli başarı için kritik öneme sahiptir.

Bu müşteri grubu, özellikle laboratuvarlar, özel ve devlet üniversitelerinin biyomoleküler bölümleri ile doktora tez çalışmalarında kullanılan testler ve hastalık teşhis kitlerini satın alan bir müşteri segmentini temsil etmektedir. Bu bağlamda, müşteri segmentinin spesifik ihtiyaçlarını karşılamak üzere özel bir strateji geliştirmek önemlidir. Bu müşterilere daha iyi hizmet sunmak adına, ürün uyumluluğunu ve adaptasyonunu vurgulayarak, laboratuvar koşullarına ve araştırma projelerine uygun ürünler sağlamaya odaklanabiliriz. Eğitim ve destek hizmetleri ile müşterilere ürünlerin etkili kullanımı konusunda destek olabilir ve işbirlikçi araştırma projeleri ile üniversitelerle güçlü bir iş birliği geliştirebiliriz.

Ayrıca, özel fiyatlandırma ve indirimlerle müşteri memnuniyetini artırarak, düzenli geri bildirim toplama mekanizmalarıyla müşteri ihtiyaçlarına daha iyi yanıt verebiliriz. Bu stratejiler, bu özel müşteri grubu ile uzun vadeli iş ilişkileri kurmak ve sürdürmek adına etkili bir çerçeve oluşturabilir.

Üçüncü kümenin R değeri ($\overline{X}$ =0,1960) F değeri ($\overline{X}$ = 0,0137), M ($\overline{X}$ =0,0115) ve L ($\overline{X}$ = 0,1514) değeri ortalama altındadır ve küme "(L↓R↓F↓M↓)" olarak adlandırılmıştır. Bu kümede bulunan müşteriler genellikle bir işletmenin potansiyel müşteri tabanındaki kişileri ifade eder. Bu müşteriler, hala işletme ile bir alışveriş veya işlem gerçekleştirmemiş, dolayısıyla henüz belirgin bir şekilde kategorize edilmemiş veya işletme ile etkileşimde bulunmamış kişilerdir. "(L↓R↓F↓M↓)" kümesindeki müşteriler "belirsiz yeni müşteriler olarak tanımlanmıştır.

Bu belirsiz yeni müşteri grubu için daha etkili bir strateji oluşturmak adına şu önerilere odaklanabiliriz: Öncelikle, hedef kitlenin ihtiyaçlarını ve beklentilerini daha iyi anlamak için bir araştırma ve analiz süreci başlatmalıyız. Ardından, bu müşterilere yönelik eğitim materyalleri, web seminerleri ve bilgilendirici içerikler oluşturarak ürünlerimizin farkındalığını artırabiliriz. Özel tanıtım ve kampanyalar düzenleyerek, belirsiz yeni müşterilerin ilk alımlarını teşvik edebilir ve bu süreci özel avantajlarla destekleyebiliriz. İlk alışveriş avantajları sunarak, müşterilerin işletmemizle ilk etkileşimde bulunmaya teşvik ederek uzun vadeli sadakat oluşturabiliriz. Son olarak, düzenli ve kişiselleştirilmiş iletişim stratejileri ile belirsiz yeni müşterilerle güçlü bir bağ kurarak, onların işletmemizi daha yakından tanımalarını ve güven duymalarını sağlayabiliriz. Bu stratejiler, "(LRFM)" kümesindeki belirsiz yeni müşterilere daha etkili bir şekilde ulaşmamıza ve potansiyel müşteri tabanımızı genişletmemize yardımcı olabilir.

4.5 Uygulama Modellerinin Karşılaştırılması

Çalışmanın bu bölümünde analizini gerçekleştirdiğimiz 3 modeli karşılaştıracağız. Her bir modelin performansını detaylı bir şekilde inceleyerek, sonuçları daha kapsamlı bir şekilde değerlendireceğiz. Analiz sürecinde kullanılan kriterleri vurgulayarak, her bir modelin avantajlarını ve dezavantajlarını belirleyeceğiz. Ayrıca, bu modellerin pratik uygulamalardaki etkisini görmek amacıyla örnek senaryolara da odaklanacağız.

4.5.1 RFM Analizi ve RFMV Analizinin Kıyaslanması

Tablo 4-20: RFM-RFMV Küme Karşılaştırması

Değişkenler	Model	Küme 1	Küme 2	Küme 3
Çeşitlilik (V)	RFM	-	-	-
	RFMV	0,0436	0,0096	0,6239
Güncellik (R)	RFM	0,7149	0,1436	0,1436
	RFMV	0,1358	0,7018	0,0203
Sıklık (F)	RFM	0,0051	0,4444	0,5431
	RFMV	0,0537	0,005	0,5318
Parasallık (M)	RFM	0,0044	0,0191	0,2876
	RFMV	0,2011	0,0043	0,2897
Genel Küme Ortalaması	RFM	0,3600	0,2024	0,3248
	RFMV	0,1086	0,1802	0,3664

RFM ve RFMV modelleri, müşteri segmentasyonu için kullanılan iki farklı yöntemdir. RFM, güncellik (son satın alma tarihi), sıklık (satın alma sıklığı) ve parasallık (harcama tutarı) değişkenlerini kullanarak müşterileri segmente eder. RFMV ise bu üç değişkenin yanı sıra variety (çeşitlilik) değişkenini de kullanır. Sonuçlara göre, RFM ve RFMV modelleri tarafından oluşturulan 3 küme arasındaki farklar aşağıdaki gibidir:

1.Küme: Her iki modelde de küme 1, en yakın tarihli ve en sık alışveriş yapan müşterilere sahiptir. RFMV modelinde, küme 1'deki müşterilerin harcama tutarları, RFM modeline göre daha yüksektir.

2.Küme: Her iki modelde de küme 2, daha uzak tarihli ve daha az sık alışveriş yapan müşterilere sahiptir. RFMV modelinde, küme 2'deki müşterilerin harcama tutarları, RFM modeline göre daha düşüktür.

3.Küme: Her iki modelde de küme 3, uzak tarihli ve daha az sık alışveriş yapan müşterilere sahiptir. RFM modelinde, küme 3'teki müşterilerin harcama tutarları, küme 2'ye göre daha düşüktür.

Bu farklılıklar, RFMV modelinin RFM modeline göre daha geniş bir perspektif sunduğunu göstermektedir. RFMV modeli, müşteri davranışlarını daha iyi anlamamızı ve daha doğru segmentasyonlar yapmamızı sağlar.

Daha spesifik olarak, küme 1'deki müşterilerin harcama tutarlarının RFMV modelinde daha yüksek olması, bu müşterilerin daha değerli olabileceğini göstermektedir. Bu müşteriler, şirketin en sadık ve en karlı müşterileri arasında olabilir. Küme 2'deki müşterilerin harcama tutarlarının RFMV modelinde daha düşük olması, bu müşterilerin potansiyel olarak daha az değerli olabileceğini göstermektedir. Bu müşteriler, şirketin pazarlama kampanyaları ile yeniden kazanılabilir. Küme 3'teki müşterilerin harcama tutarlarının RFM modelinde daha düşük olması, bu müşterilerin potansiyel olarak daha az değerli olabileceğini göstermektedir. Bu müşteriler, şirketin yeni ürünler ve hizmetler geliştirmesi ile ilgilerini çekebilir. Bir şirket, bu farklılıkları kullanarak, pazarlama stratejilerini geliştirebilir. Örneğin, şirket, küme 1'deki müşterileri hedeflemek için özel teklifler ve indirimler sunabilir. Küme 2'deki müşterileri hedeflemek için, bu müşterileri yeniden kazanmak için kampanyalar düzenleyebilir. Küme 3'teki müşterileri hedeflemek için, bu müşterilerin ilgisini çekecek yeni ürünler ve hizmetler geliştirebilir.

RFM ve RFMV, müşteri segmentasyonu için kullanılan iki farklı yöntemdir. İki yöntem arasında %60.5 oranında ortak müşteri kümeleri bulunmaktadır. Ancak, RFM'nin birinci kümeye yerleştirdiği müşterilerin %32.37'si, RFMV analizine göre iki ayrı kümeye ayrılmıştır. Tablo4-21'de RFM ve RFMV analizlerine ait kıyaslama sonuçlarına yer verilmiştir:

Tablo 4-21: RFM-RFMV Kıyaslama

		RFMV			Total
		1.00	2.00	3.00	
RFM	1.00	138	67	2	207
	2.00	5	0	15	20
	3.00	0	0	1	1
Total		143	67	18	228

Tablo4-21'e göre, RFM analizinde birinci kümede 138 müşteri, ikinci kümede 67 müşteri, üçüncü kümede 2 müşteri bulunmaktadır. Ancak, RFMV analizine göre, RFM'nin birinci kümeye yerleştirdiği müşterilerin %32.37'si ikinci kümeye ayrılmıştır. Diğer yandan, RFM'nin ikinci küme olarak değerlendirdiği müşteriler RFMV analizine göre genellikle üçüncü kümeye dahil edilmiştir.

Bu sonuçlar, her iki analiz yöntemi arasındaki benzerlikleri ve farklılıkları ortaya koymaktadır. RFM ve RFMV analizlerinin müşteri segmentasyonunda birlikte kullanılması durumunda, ortak müşteri kümelerinin yanı sıra belirli farklılıkları da dikkate almak önemlidir.

4.5.2 RFM Analizi ve LRFM Analizinin Kıyaslanması

Bu aşamada analizini yaptığımız RFM ve LRFM için genel bir karşılaştırılma yapılmaktadır. İki analizin de değerleri göz önünde bulundurularak firma için etkileri incelenecektir. Normalizayon sonucu elde ettiğimiz veriler aşağıdaki tabloda verilmiştir.

Tablo 4-22: RFM-LRFM Küme Karşılaştırılması

Değişkenler	Model	Küme 1	Küme 2	Küme 3
Uzunluk (L)	RFM	-	-	-
	LRFM	0,4740	0,8685	0,1514
Güncellik (R)	RFM	0,7149	0,1436	0,1436
	LRFM	0,7274	0,0377	0,196
Sıklık (F)	RFM	0,0051	0,4444	0,5431
	LRFM	0,0047	0,2446	0.0137
Parasallık (M)	RFM	0,0044	0,0191	0,2876
	LRFM	0,0045	0,1064	0,0115
Genel Küme Ortalaması	RFM	0,3600	0,2024	0,3248
	LRFM	0,3027	0,3143	0,1196

RFM ve LRFM modelleri, müşteri segmentasyonu için kullanılan iki farklı yöntemdir. RFM, güncellik (son satın alma tarihi), sıklık (satın alma sıklığı) ve parasallık (harcama tutarı) değişkenlerini kullanarak müşterileri segmente eder. LRFM (length) ise bu üç değişkenin yanı sıra uzunluk (satın alma geçmişinin uzunluğu) değişkenini de kullanır.

Sonuçlara göre, RFM ve LRFM modelleri tarafından oluşturulan 3 küme arasındaki farklar aşağıdaki gibidir:

Küme 1: Her iki modelde de küme 1, en yakın tarihli ve en sık alışveriş yapan müşterilere sahiptir. LRFM modelinde, küme 1'deki müşterilerin satın alma geçmişlerinin uzunluğu, RFM modeline göre daha uzundur. Küme 2: Her iki modelde de küme 2, daha uzak tarihli ve daha seyrek alışveriş yapan müşterilere sahiptir. LRFM modelinde, küme 2'deki müşterilerin satın alma geçmişlerinin uzunluğu, RFM modeline göre daha kısadır. Küme 3: Her iki modelde de küme 3, uzak tarihli ve daha seyrek alışveriş yapan müşterilere sahiptir. RFM modelinde, küme 3'teki müşterilerin satın alma geçmişlerinin uzunluğu, küme 2'ye göre daha kısadır.

Bu farklılıklar, LRFM modelinin RFM modeline göre daha geniş bir perspektif sunduğunu göstermektedir. LRFM modeli, müşteri davranışlarını daha iyi anlamamızı ve daha doğru segmentasyonlar yapmamızı sağlar. Daha spesifik olarak, küme 1'deki müşterilerin satın alma geçmişlerinin uzunluğunun LRFM modelinde daha uzun olması, bu müşterilerin daha sadık olabileceğini göstermektedir. Bu müşteriler, şirketin en sadık ve en karlı müşterileri arasında olabilir.

Küme 2'deki müşterilerin satın alma geçmişlerinin uzunluğunun LRFM modelinde daha kısa olması, bu müşterilerin potansiyel olarak daha az sadık olabileceğini göstermektedir. Bu müşteriler, şirketin pazarlama kampanyaları ile yeniden kazanılabilir. Küme 3'teki müşterilerin satın alma geçmişlerinin uzunluğunun RFM modelinde daha kısa olması, bu müşterilerin potansiyel olarak daha az değerli olabileceğini göstermektedir. Bu müşteriler, şirketin yeni ürünler ve hizmetler geliştirmesi ile ilgilerini çekebilir. Bir şirket, bu farklılıkları kullanarak, pazarlama stratejilerini geliştirebilir. Örneğin, şirket, küme 1'deki müşterileri hedeflemek için özel teklifler ve indirimler sunabilir. Küme 2'deki müşterileri hedeflemek için, bu müşterileri yeniden kazanmak için kampanyalar düzenleyebilir. Küme 3'teki müşterileri hedeflemek için, bu müşterilerin ilgisini çekecek yeni ürünler ve hizmetler geliştirebilir.

Özellikle, LRFM modelinin RFM modeline göre en önemli farkı, satın alma geçmişinin uzunluğunu dikkate almasıdır. Satın alma geçmişinin uzunluğu, müşterinin bir şirkete olan bağlılığını ve bağlılığını ölçmek için kullanılan bir ölçümdür. LRFM modeli, satın alma geçmişinin uzunluğunu dikkate alarak, daha doğru bir şekilde müşteri segmentasyonu yapmamızı sağlar. Örneğin, bir şirket, müşterilerin satın alma geçmişlerini takip etmek için bir müşteri sadakat programı uygulayabilir. Bu program, müşterilerin satın alma davranışlarını ve sadakat düzeylerini ölçmek için kullanılabilir.

LRFM modeli, bu verileri kullanarak, daha doğru bir şekilde müşterileri segmente edebilir. Bu, şirketin pazarlama stratejilerini daha etkili bir şekilde geliştirmesine yardımcı olabilir.

Ek Boyut; "Uzunluk" iki şekilde anlamlandırılabilir müşterinin işletme ile ilişkisinin süresini veya müşterinin şirketle ne kadar süredir etkileşimde bulunduğunu temsil ediyorsa bu müşteri ilişkisinin süresine dair yeni bir boyutu gösterir. Eğer "Uzunluk" değişkeni LRFM içinde müşterinin işletme ile ilişkisinin süresini temsil ediyorsa, modeli müşteri ilişkisinin ne kadar süreyle devam ettiğine dair bir içgörü sağlamak için bir zamansal boyut ekler. RFM, son alışveriş davranışına, sıklığa ve parasal değere dair içgörüler sağlarken, "Uzunluk" değişkeni eklenmiş LRFM, müşterinin ilişki süresi ve bağlılık konusunda içgörüler sunabilir.

RFM analizi ve LFRM analizi sonuçları incelendiğinde, her iki yöntemin de aynı kategoride değerlendirdiği müşterilerin oranı %37.98 olarak belirlenmiştir. Bu oran, toplam müşteri sayısına göre hesaplanmıştır.

Tablo 4-23: RFM-LRFM Kıyaslama

		LRFM			Total
		1.00	2.00	3.00	
RFM	1.00	61	46	100	207
	2.00	0	18	2	20
	3.00	0	1	0	1
Total		61	65	102	228

RFM analizi sonuçlarına göre, 207 müşteri birinci gruba, 20 müşteri ise ikinci gruba atanmıştır. Ancak, LRFM analizi, RFM'nin birinci kümede bulunan müşterilerinin %29.47'sini (61 kişi) birinci grupta değerlendirmiştir. Bu durum, RFM ve LFRM analizleri arasındaki farkları göstermektedir.

LFRM analizi ile RFM analizinin birinci kümede bulundurduğu müşterilerin %22'si ikinci gruba, %48'i ise üçüncü gruba atanmıştır. Uzunluk değişkeni devreye girdiğinde, müşterilerin segmentlendirilmesinde daha detaylı bir yaklaşım sağlanmış ve gruplara daha dengeli bir dağılım elde edilmiştir.

LRFM-RFMV Kıyaslanması

Tablo 4-24'e göre, LRFM analizine göre birinci kümede hiç müşteri bulunmamaktadır. Ancak, ikinci kümede 61 müşteri, üçüncü kümede ise 65 müşteri yer almaktadır. Bu durum, uzunluk değişkeni eklenmesiyle müşterilerin RFMV analizine göre farklı kümelerde yer aldığını göstermektedir.

Tablo 4-24: LRFM-RFMV Kıyaslama

		RFMV			Total
		1.00	2.00	3.00	
LRFM	1.00	0	61	0	61
	2.00	48	0	17	65
	3.00	95	6	1	102
Total		143	67	18	228

RFMV analizine göre birinci kümeye yerleştirilen müşterilerin uzunluk değişkeni devreye girdiğinde, bu müşterilerin %33.5'i ikinci kümeye, %66.5'i ise üçüncü kümeye ayrılmıştır. Yani, uzunluk değişkeni, RFMV analizinde belirlenen kümelerin içinde daha detaylı bir ayrım yapmış ve müşterileri daha özgün şekillerde sınıflandırmıştır. Bu durum, analiz sonuçlarının daha önce belirlenen kümeler içindeki homojenliği artırdığını ve müşteri davranışlarını daha ayrıntılı bir şekilde değerlendirdiğini göstermektedir.

4.5.3 RFM, LRFM ve RFMV Analizlerinin Kıyaslanması

Bu aşamada analizini yaptığımız RFM, RFM-V ve LRFM için genel bir karşılaştırılma yapılmaktadır. 3 analizin de değerleri göz önünde bulundurularak firma için etkileri incelenecektir. Normalizasyon sonucu elde ettiğimiz veriler aşağıdaki tabloda verilmiştir.

Tablo 4-25: Modellerin Karşılaştırılması

Değişkenler	Model	Küme 1	Küme 2	Küme 3
Güncellik (R)	RFM	0,7149	0,1436	0,1436
	RFM-V	0,1358	0,7018	0,0203
	LRFM	0,7274	0,0377	0,196
Sıklık (F)	RFM	0,0051	0,4444	0,5431
	RFM-V	0,0537	0,005	0,5318
	LRFM	0,0047	0,2446	0.0137
Parasallık (M)	RFM	0,0044	0,0191	0,2876
	RFM-V	0,2011	0,0043	0,2897
	LRFM	0,0045	0,1064	0,0115
Genel Küme Ortalaması	RFM	0,36	0,2024	0,3248
	RFMV	0,1086	0,1802	0,3664
	LRFM	0,3027	0,3143	0,1196

RFM, RFMV ve LRFM kümeleri, müşterilerin davranışlarını farklı yönlerden sınıflandırmak için tasarlanmış üç farklı modeldir. Hangi modelin iyi olduğu, belirli uygulamaya ve hedeflere bağlıdır.

RFM analizi, müşterilerin satın alma sıklığı, parasallık ve güncellik gibi temel değişkenlerine odaklanır. Bu, müşterilerin değerini ve potansiyelini belirlemek için basit ve etkili bir yöntemdir. RFMV analizi, RFM analizine bir değişken daha ekleyerek, müşterilerin satın alma çeşitliliğini de dikkate alır. Müşterilerin satın alma davranışlarını daha ayrıntılı bir şekilde anlamaya yardımcı olur.

LRFM analizi de RFM analizine bir değişken daha ekleyerek, müşterilerin satın alma yaşam döngüsünü dikkate alır. Bu, müşterilerin satın alma davranışlarını zaman içinde izlemeye yardımcı olur.

Sıklık, parasallık ve güncellik gibi temel değişkenleri dikkate alan basit ve etkili bir yöntemden yararlanılmak isteniliyorsa, RFM analizi iyi bir seçimdir. Müşterilerin satın alma davranışlarını daha ayrıntılı bir şekilde anlamak isteniliyorsa, RFMV analizi daha iyi bir seçenektir. Müşterilerin satın alma davranışları zaman içinde izlemek isteniyorsa LRFM analizi en iyi seçenektir.

Aşağıda üç analiz için müşteri grupları A, B ve C olarak açıklanmıştır. A, B ve C sınıfı müşteriler, müşteri değerine göre sınıflandırılmış müşterilerdir. Müşteri değeri, bir müşterinin bir şirkete sağladığı toplam faydayı ifade eder (Frederick F. Reichheld, 1996). Bu fayda, müşterinin satın alma sıklığı, parasallık ve satın alma yaşam döngüsü gibi faktörlere göre hesaplanabilir. A sınıfı müşteriler, en yüksek müşteri değerine sahiptir. Bu müşteriler, genellikle sık sık satın alır, yüksek miktarda para harcar ve uzun bir satın alma yaşam döngüsüne sahiptir. A sınıfı müşteriler, bir şirketin en değerli müşterileridir ve özel ilgi ve promosyonlara ihtiyaç duyarlar. B sınıfı müşteriler, orta düzeyde müşteri değerine sahiptir. Bu müşteriler, genellikle A sınıfı müşteriler kadar sık satın almaz, ancak yine de önemli bir miktarda para harcar. B sınıfı müşteriler, özel ilgi ve promosyonlardan yararlanabilir. C sınıfı müşteriler, en düşük müşteri değerine sahiptir. Bu müşteriler, genellikle nadiren satın alır, düşük miktarda para harcar ve kısa bir satın alma yaşam döngüsüne sahiptir. C sınıfı müşteriler, özel ilgi veya promosyon gerektirmeyebilir. (Frederick F. Reichheld, 1996).

Küme 1

RFM: A sınıfı müşteriler, yüksek satın alma sıklığı, parasallık ve güncellik değerlerine sahiptir. Bu müşteriler, şirketin en değerli müşterileridir ve özel ilgiye ve promosyonlara ihtiyaç duyarlar.

RFMV: A sınıfı müşteriler, yüksek satın alma sıklığı, parasallık, güncellik ve çeşitlilik değerlerine sahiptir. Bu müşteriler, şirketin en değerli ve potansiyel müşterileridir ve özel ilgiye ve promosyonlara ihtiyaç duyarlar.

LRFM: A sınıfı müşteriler, yeni müşterilerdir, ancak yüksek satın alma sıklığı, parasallık ve güncellik değerlerine sahiptir. Bu müşteriler, şirketin potansiyel müşterileridir ve elde tutulmaları için özel ilgiye ve promosyonlara ihtiyaç duyarlar.

Küme 2

RFM: B sınıfı müşteriler, yüksek satın alma sıklığı ve parasallık değerlerine sahiptir, ancak güncellik değerleri düşüktür. Bu müşteriler, şirketin değerli müşterileridir, ancak satın alma davranışlarında bir azalma olabilir. Bu müşteriler, özel ilgi ve promosyonlarla yeniden kazanmaya çalışılmalıdır.

RFMV: B sınıfı müşteriler, yüksek satın alma sıklığı, parasallık ve çeşitlilik değerlerine sahiptir, ancak güncellik değerleri düşüktür. Bu müşteriler, şirketin değerli ve potansiyel müşterileridir, ancak satın alma davranışlarında bir azalma olabilir. Bu müşteriler, özel ilgi ve promosyonlarla yeniden kazanmaya çalışılmalıdır.

LRFM: B sınıfı müşteriler, şirketin potansiyel müşterileridir, ancak satın alma davranışlarında bir azalma olabilir. Bu müşteriler, özel ilgi ve promosyonlarla yeniden kazanmaya çalışılmalıdır.

Küme 3

RFM: C sınıfı müşteriler, düşük satın alma sıklığı ve parasallık değerlerine sahiptir. Bu müşteriler, şirketin düşük değerli müşterileridir ve dikkate alınmaları gerekmeyebilir.

RFMV: C sınıfı müşteriler, düşük satın alma sıklığı, parasallık ve çeşitlilik değerlerine sahiptir. Bu müşteriler, şirketin düşük değerli ve potansiyel müşterileridir ve dikkate alınmaları gerekmeyebilir.

LRFM: C sınıfı müşteriler, yeni müşterilerdir, ancak düşük satın alma sıklığı ve parasallık değerlerine sahiptir. Bu müşteriler, şirketin düşük değerli potansiyel müşterileridir ve dikkate alınmaları gerekmeyebilir.

Şirketin ana hedefi, mevcut müşterilerini korumak ve yeni müşteriler kazanmaksa, küme 1 ve küme 2'deki müşterilere odaklanmak gerekir. Şirketin ana hedefi, düşük değerli müşterileri dönüştürmekse, küme 2 ve küme 3'teki müşterilere odaklanmak gereklidir. Şirketin pazarlama bütçesi sınırlıysa, küme 1 ve küme 2'deki müşterilere odaklanmak daha iyi bir seçenektir. Şirketin pazarlama bütçesi yeterliyse, küme 1, küme 2 ve küme 3'teki müşterilere odaklanmak daha iyi bir seçenektir. Kümeleri karşılaştırmak, şirketlerin pazarlama stratejilerini geliştirmelerine ve müşteri davranışlarını daha iyi anlamalarına yardımcı olabilir.

Amaç, basitlik, anlaşılabilirlik, doğruluk ve öneri kriterleri üzerinden yapılan genel değerlendirmeye göre, üç model aşağıdaki gibi karşılaştırılmıştır.

Tablo 4-26: Model Değerlendirilmesi

MODELLER	RFM	RFMV	LRFM
Amaç	Müşterileri yakınlık, frekans ve parasallık açısından segmente etmek	Müşterileri yakınlık, frekans, parasallık ve müşteri derinliği açısından segmente etmek	Müşterileri yakınlık, frekans, parasallık ve müşteri ilişkisinin süresi açısından segmente etmek
Basitlik	Kolay	Orta	Orta
Anlaşılabilirlik	Kolay	Orta	Orta
Doğruluk	Orta	Yüksek	Orta
Öneri	İyi başlangıç noktası	Daha doğru segmentasyon için	Daha uzun vadeli müşteri ilişkileri için

RFM modeli işletmenizde yeni olarak yapmaya başlanılıyor veya basit ve anlaşılması kolay bir model aranıyorsa, RFM modeli iyi bir seçenektir. RFMV modeli işletmeniz daha doğru segmentasyon sonuçları aranıyorsa veya satın alma derinliğini de dikkate almak isteniyorsa, RFMV modeli daha iyi bir seçenektir. İşletmenizin uzun vadeli müşteri ilişkileri geliştirmek gibi bir hedefi varsa, LRFM modeli daha iyi bir seçenektir.

5. SONUÇ VE ÖNERİLER

Müşteri segmentasyonunun işletmeler için taşıdığı önem vurgulanmış ve bu sürecin mevcut müşterilerin kim olduğunu tanıma, onları şirketimize bağlı kılma ve potansiyel müşterilerin şirketimizle nasıl etkileşimde bulunabileceğini belirleme konularında kritik bir rol oynadığına dikkat çekilmiştir. Günümüz rekabet ortamında, müşteriyi anlamanın ve tanımanın büyük bir önem arz ettiği vurgulanarak, bu ihtiyacın gün geçtikçe arttığına vurgu yapılmıştır.

Segmentasyon kavramı, işletmelerin mevcut müşterilerinin kim olduğunu tanımada bu müşterilerin şirketimizden alışveriş yapmaya devam ettirilmesinde ve müşterimiz olmayan kişilerin şirketimiz bünyesinde nasıl alışveriş yapar noktasını belirlemede noktasında oldukça önemlidir. Rekabetin daha da artığı günümüzde müşteriyi anlamak ve tanımak büyük bir önem kazanmaktadır. Yapılan uygulamada veri madenciliği teknikleri kullanılarak 3 model üzerinde durulmuştur. Bu modeller yardımıyla müşterilerimizin kim olduğu ve bu müşteriler için pazarlama stratejileri uygulanabileceği açıklanmaya çalışılmıştır.

Veri madenciliği teknikleri kullanılarak yapılan uygulamada, RFM, RFMV ve LRFM modellerine odaklanılmıştır. Bu modeller, müşteri segmentasyonunda kullanılarak mevcut müşteri konumları değerlendirilmiş ve pazarlama stratejileri oluşturulmaya çalışılmıştır. Veriler, İstanbul merkezli bir biyoteknoloji şirketinin altyapısından elde edilmiş ve bu sektördeki önemli analizlere odaklanılmıştır. Çalışmanın ikinci bölümünde, müşteri ilişkileri yönetimi, veri madenciliği modelleri ve kullanılan modeller detaylı olarak tanıtılmıştır. Üçüncü bölümde literatürde daha önce yapılmış çalışmalara değinilmiştir.

Dördüncü bölüm uygulamanın yer aldığı bölümdür. Bu bölümde uygulamanın yapıldığı biyoteknoloji şirketinin CRM verileri incelenmiştir. İkinci bölümde teorik olarak anlatılan RFM, RFMV ve LRFM modelleri detaylı olarak hesaplanmıştır. Üç model ayrı ayrı değerlendirilmiştir. Her modelin kendi içinde yer alan değişkenlerinin önemine yer verilmiştir.

Yapılan çalışma bir biyoteknoloji sektörü verilerini kullanmış olup 3 farklı segmentasyon yöntemi ile değerlendirilmiştir. Yapılan her bir segmentasyon yöntemi ile mevcut müşterilerimizin şirket için konumu değerlendirilmiştir. Burada amaç kullanılan her bir segmentasyon yöntemi açısından müşterilerimizin farklı bir kümede değerlendirilip değerlendirilmediğini gözlemlemektir. Verilerini kullanmış olduğumuz sektör açısından kullanılacak en iyi yöntemi belirlemek karar vereceğimiz pazarlama stratejileri, aksiyon alacağımız gelecek adımlarımız ve en önemlisi müşterilerimiz daha iyi tanımak için oldukça önemlidir.

Çalışma, B2B (işletmeden işletmeye) biyoteknoloji sektöründe RFM (Recency, Frequency, Monetary) analizi alanında tespit edilen bir boşluğa odaklanmaktadır. Daha önce biyoteknoloji alanındaki B2B pazarlaması literatüründe sınırlı sayıda çalışma bulunmasına rağmen, RFM modelinin bu sektördeki uygulanabilirliği ve etkinliği konusunda bir eksiklik bulunmaktadır. Bu çalışma, biyoteknoloji sektöründeki B2B işletmelerinin müşteri davranışlarını anlama, segmentasyon yapma ve özelleştirilmiş pazarlama stratejileri geliştirme amacıyla RFM analizini nasıl kullanabilecekleri konusundaki bu boşluğu doldurmayı amaçlamaktadır. Bu analiz, biyoteknoloji sektöründeki işletmelerin müşteri odaklı stratejilerini güçlendirmelerine ve rekabet avantajı elde etmelerine yardımcı olabilecek önemli içgörüler sağlanabilir.

En iyi model şirketin hedeflerine ve mevcut kaynaklarına bağlıdır. Ancak genel olarak, RFMV veya LRFM modelinin kullanılması önerilir. RFMV modeli, satın alma sıklığı, parasallık ve çeşitlilik değişkenlerini kullanarak, müşterilerin satın alma davranışlarını daha ayrıntılı bir şekilde anlamasına yardımcı olur. Bu, biyoteknoloji şirketlerinin, müşterilerinin ihtiyaçlarına ve beklentilerine daha iyi hitap edebilmelerini sağlar. LRFM modeli, satın alma sıklığı, parasallık, çeşitlilik ve satın alma yaşam döngüsü değişkenlerini kullanarak, müşterilerin satın alma davranışlarını zaman içinde izlemesine yardımcı olur. Bu, biyoteknoloji şirketlerinin, müşterilerinin ihtiyaçlarını ve beklentilerini daha iyi anlayarak, onlara daha kişiselleştirilmiş bir deneyim sunabilmelerini sağlar.

Örneğin, bir biyoteknoloji şirketi, yeni bir ürünü piyasaya sürmek istiyorsa, RFMV veya LRFM modelini kullanarak, bu ürünün hedef kitlesini ve pazarlama stratejisini belirleyebilir. Şirket, bu bilgileri kullanarak, ürünün başarılı bir şekilde piyasaya sürülmesini sağlayabilir. Bir başka örnek olarak, bir biyoteknoloji şirketi, mevcut müşterilerini elde tutmak istiyorsa, RFMV veya LRFM modelini kullanarak, bu müşterilerin ihtiyaçlarını ve beklentilerini anlayabilir. Şirket, bu bilgileri kullanarak, müşterilerini özel teklifler sunarak elde tutmaya çalışabilir.

Fakat daha da şirket genelini ele alırsak müşteri derinliği yüksek olan müşteriler, daha sadık ve değerli müşteriler olma eğilimindedir. RFM-V modeli, bu tür müşterileri daha doğru bir şekilde tanımlayabildiği için, biyoteknoloji firmaları için daha uygun bir modeldir. Biyoteknoloji sektörü, yüksek teknolojili ve rekabetçi bir sektördür. Bu sektörde faaliyet gösteren firmalar, müşteri segmentasyonunu kullanarak, pazarlama çabalarını daha etkili bir şekilde yönlendirebilirler. RFM-V modeli, biyoteknoloji firmalarının, müşteri derinliğini ölçerek, daha değerli müşterilere odaklanmalarını sağlayabilir.

Her bir araştırmacı, müşterileri segmente edebilmek amacıyla RFM modellerini farklı parametrelerle genişletmiştir. Bu genişletmeler genellikle, RFM modelinin müşterileri değerlendirirken yetersiz olduğu düşünülen kriterleri ele almasından kaynaklanmaktadır. Örneğin Yeh, Yang, & Ting (2008) bir veri tabanından doğrudan iki parametre ekleyerek, ilk satın alma tarihini (T) ve kayıp olasılığını (C) pazarlama hedefleri seçmek için genişletilmiş bir RFM modeli olan RFMTC'yi

kullanmıştır. Chang & Tsai, (2011) sorunu hafifletmek için GRFM (grup RFM) analizi adı verilen yeni bir çerçeve önermiştir. Bu ölçüm yöntemi, satın alınan ürünlerin özelliklerini dikkate alır, bu nedenle müşteriler için hesaplanan RFM değerleri, satın alınan ürünleriyle güçlü bir şekilde ilişkilidir ve gerçek tüketim davranışlarını doğru bir şekilde yansıtmasını hedeflemiştir. Ayrıca Alvandi, Fazli, & Abdoli (2012) uzunluğu (L) dikkate alarak LRFM modeli olarak genişletmişlerdir. Yeni ölçüm yöntemleri, satın alınan ürünlerin özelliklerini dikkate alır, bu nedenle müşteriler için hesaplanan RFM değerleri, satın aldıkları ürünlerle güçlü bir şekilde ilişkilidir ve gerçek tüketim davranışlarını doğru bir şekilde yansıtabilir.

Tüm bu ek parametreleri değerlendirip göz önüne alındığında, kendi sektörümüzü ve müşteri kitlemizi tanımanın önemli bir husus haline geldiğini fark edilir. Çünkü bu süreç, şirketimiz için en uygun parametreleri belirlememize olanak tanır. Bu analizler sayesinde, daha doğru, uygulanabilir ve yüksek geri dönüşümlü stratejiler geliştirebiliriz. Doğru parametrelerin seçilmesi, müşteri kitlesini anlamamıza ve buna bağlı olarak daha etkili tutundurma stratejileri ve reklam kampanyaları oluşturmamıza yardımcı olacaktır. Bu da şirket karlılığı için büyük önem taşır. Her sektörün ve müşteri kitlesinin özgün özellikleri olduğu için, spesifik parametreleri tanımlayarak şirketimizin ihtiyaçlarına en uygun stratejileri belirleyebiliriz.

Müşteri segmentasyonu ve ihtiyaç analizi, şirketin hedef kitlesini daha iyi anlamasını sağlar. Bu, ürün ve hizmetlerin daha etkili bir şekilde pazarlanmasına, müşteri memnuniyetinin artırılmasına ve uzun vadeli müşteri ilişkilerinin güçlendirilmesine olanak tanır. Bu nedenle, doğru parametreleri seçerek gerçekleştirilen analizler, şirketimizin rekabet avantajını artırabilir ve başarılı bir pazarlama stratejisi oluşturabilir.

Gelecekteki araştırmalar için, şirket dinamiklerini dikkate alarak geleneksel RFM modeline yeni parametreler eklenerek müşteri segmentasyon modelleri oluşturulması oldukça önemli bir alanı temsil etmektedir. Bu çalışma, mevcut müşteri segmentasyon modellerini genişleterek şirketlere daha etkili ve özelleştirilmiş pazarlama stratejileri geliştirmelerine yardımcı olabilir. Çalışma kapsamında, RFM modeline entegre edilen yeni parametrelerle birlikte üç farklı model detaylı bir şekilde incelenmiş, tanıtılmış, analiz edilmiş ve kıyaslanmıştır. Bu, mevcut literatürdeki boşlukları doldurarak gelecek araştırmalar için sağlam bir temel oluşturabilir.

Ayrıca, çalışmanın amacı, sadece üç modelin ötesine geçmek değil, aynı zamanda yeni parametrelerin eklenmesiyle farklı model dinamiklerinin nasıl oluşturulabileceğini incelemektir. Bu, şirketlerin müşteri tabanını daha iyi anlamalarına ve özelleştirilmiş stratejiler geliştirmelerine olanak tanıyan yenilikçi yaklaşımlar sunabilir.

Gelecekteki araştırmalara yönelik öneri olarak, çalışmanın bulguları doğrultusunda şirketlerin sektörlerine özgü olarak yeni parametreleri uyarlayabilecekleri, bu parametrelerin etkilerini değerlendirebilecekleri ve müşteri segmentasyon modellerini sürekli olarak optimize edebilecekleri bir çerçeve geliştirilebilir. Ayrıca, bu çalışma, gelecekteki akademik araştırmalara ilham kaynağı olabilir ve müşteri segmentasyonu konusundaki literatürü daha da zenginleştirebilir.

KAYNAKÇA

Aleksandrova Y. (2018), Application Of Machine Learning For Churn Predıction Based On Transactional Data (Rfm Analysis), 18th International Multidisciplinary Scientific GeoConference SGEM

Alvandi M., Fazli S. ve Seifi Abdoli F. (2012) K-Mean Clustering Method For Analysis Customer Lifetime Value With LRFM Relationship Model In Banking Services, International Research Journal of Applied and Basic Sciences, Sy2294-2302,C3

Başkol M. (2020) RFM ve Uyum Analizi Kullanılarak Müşteri Segmentasyonunun Belirlenmesi, Busıness & Management Studıes: An Internatıonal Journal, Sy902-928,C8

Buttle, F., & Maklan, S. (2015). *Customer Relationship Management* . Concepts and Technologies .

Chang W.J, Chang Y. ve Lin C. (2015) Analyzing Patient Value by Modifying RFM Model With Consideration of The Limitation of Service Throughput: An Investigation of Dental Health Care, Proceedings of The Fourth International Conference on Informatics & Applications, Sy75-82

Chen D., Laing S. ve Guo K. (2012), Journal of Database Marketing & Customer Strategy Management, Sy197-208,C19

Couldwell, C. (1999). Loyalty Bonuses. *Marketing Week*, 14.

Frederick F. Reichheld, T. T. (1996). *The Loyalty Effect.*

Han P. Kamber M. Pei J. (2012). *Data Mining Concepts and Techniques.*

Han, J., Kamber, M., & Pei, J. (2012). *Data Mining Concepts and Techniques* . Morgan Kaufman.

Jamunadevi C., Tamil Selvan S., Govindarajan M., Saravanan C. ve Janaki B. (2021) LRFM Model for Customer Purchase Behaviour Using Kmeans Algorithm, IOP Conf. Series: Materials Science and Engineering

Khajvand M., Zolfaghar K., Ashoori S. ve Alizadeh S. (2011), Estimating customer lifetime value based on RFM analysis of customer purchase behavior: case study, Procedia Computer Science, Sy57–63,C3

Kotler, P. (1980). *Principles Marketing* (s. 291-309). içinde Englewood Cliffs,New Jersey, Prentice-Hall.

Kumar, V., & Reinartz, W. (2006). V. Kumar, & W. Reinartz içinde, *Customer Relationship Management* . Springer.

Larose, D. T. (2006). *Data Mining Methods and Models.* John Wiley&Sons.

Levent SABAH, H. B. (2020). Veri Madenciliği Birliktelik Kuralları ile Binaların Risk Durumlarının Analizi. *Gazi Mühendislik Bilimleri Dergisi*, 70-78.

MacQueen, J. (1967). Some Methods for Classification and Analysis of Multivariate Observations. *In: Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability,* (s. 281). Berkeley: University of California .

Madhulatha, T. S. (2012). An Overvıew On Clusterıng Methods. *Iosr Journal of Engineering*, 719-725.

Madhulatha, T. S. (2012). An Overview On Clustering Methods. *Iosr Journal of Engineering*, 719-725.

Marcus, C. (1998). A Practical Yet Meaningful Approach to Customer Segmentation. *Journal of Consumer Marketing,*, 494–504.

Miglautsch, J. R. (2000). Thoughts on RFM scoring. *Journal of Database Marketing*, 67-72.

Nimbalkar, D. D., & Shah, P. (2013). Data mining using RFM Analysis. *International Journal of Scientific & Engineering Research*, 940-943.

Odabaşı, Y. (2004). Satış ve Pazarlamada Müşteri İlişkileri Yönetimi.

Ozkan P.ve Deveci Kocakoc İ. (2021) A Customer Segmentation Model Proposal for Retailers: RFM-V, Advances in Global Services and Retail Management, Sy1-12

Ozkan, P. &.-K. (2021). A customer segmentation model proposal for retailers: RFM-V, Advances in global services and retail management . 1–12 .

Han J, Kamber M ve Pei J (2012). *Data Mining Concepts and Techniques.*

Parikh Y ve Abdelfattah E, (2020), Clustering Algorithms and RFM Analysis Performed on Retail Transactions, IEEE Annual Ubiquitous Computing, Electronics & Mobile Communication Conference

Pegarkov, D. D. (2006). *National Security Issues.* Nova Science Publisher.

Peppers, D., Rogers, M., & Dorf, B. (1999). Is your company ready for one-to-one marketing. *Harvard Business Review*, 151-160.

Qadaki M., Abdolvand N. ve Harandi S. (2017) A RFMV Model and Customer Segmentation Based on Variety of Products, Journal of Information Systems and Telecommunication, Sy156-161,C5

Qadaki Moghaddam, A. &. (2017). A RFMV Model and Customer Segmentation Based on Variety of Products . *Journal of Information Systems and Telecommunication*, 155-161 .

Sabuncu İ., Türkan E. ve Polat H. (2020), Customer Segmentation And Profiling With RFM Analysis, TUJOM, Sy22-36,C5

Selvi, M. S. (2006). *Müşteri Sadakati.* Ankara: Detay.

Shih Y. ve Liu C. (2003) A method for customer lifetime value ranking - Combining theanalytic hierarchy process and clustering analysis, Database Marketing & Customer Strategy Management Sy159-172,C11

Swift, R. S. (2001). *Accelerating Customer Relationships using CRM and Relationship Technologies, .* Prentice Hall PTR.

Şentürk, H., & Alp, S. (2023). Perakende Sektöründe Rfm Analizi ile Müşteri Segmentasyonu. *İstanbul Ticaret Üniversitesi Girişimcilik Dergisi*, 1-10.

Tuncer İ. ve Karaboğa K. (2021), RFM Metriklerini Kullanarak Kümeleme Yöntemi ile Müşteri Bölümlendirme: Perakende Sektöründe Bir Uygulama, Üçüncü Sektör Sosyal Ekonomi Dergisi, Sy411-425,C56

Tyasnurita R. ve Kafif Ibrahim M. (2022) LRFM Model Analysis for Customer Segmentation Using K-Means Clustering, International Conference on Electrical and Information Technology