

Araştırma Makalesi

**RFM Metriklerini Kullanarak Kümeleme Yöntemi ile Müşteri
Bölümlendirme: Perakende Sektöründe Bir Uygulama**

*Customer Segmentation with Clustering Method Using RFM Metrics: An Application in
Retail Industry*

İlhami TUNCER Dr. Öğr. Üyesi, Karamanoğlu Mehmetbey Üniversitesi İİBF, Uluslararası Ticaret ve İşletmecilik ituncer@kmu.edu.tr https://orcid.org/0002-6883-4461	Kazım KARABOĞA Dr. Öğr. Üyesi, Necmettin Erbakan Üniversitesi Uygulamalı Bilimler Fakültesi Yönetim Bilişim Sistemleri kkaraboga@erbakan.edu.tr https://orcid.org/0000-0002-4365-1714
--	--

Makale Gönderme Tarihi 26.01.2021	Revizyon Tarihi 19.02.2021	Kabul Tarihi 03.03.2021
---	--------------------------------------	-----------------------------------

Öz

Dünyadaki makro faktörlerin değişimine ve gelişimine paralel olarak pazarlamada da kitlesel pazarlama anlayışından müşteri anlayışına bir geçiş süreci yaşanmıştır. Kuşkusuz bu süreçte en önemli konulardan birisi de müşteri bölümlendirmedir. Çünkü müşteri bölümlendirmenin müşteri odaklı pazarlama anlayışında müşterilerin çeşitli parametreler çerçevesinde sınıflandırılması ve kümelenmesinde önemli bir fonksiyon üstlenebilmektedir. Literatürde de uygulamadaki gelişmelere paralel olarak bu konuya ilginin arttığı ve çalışmaların zenginleştiği gözlemlenmektedir. Ancak halen bu konuda yapılan çalışmaların sınırlı olduğu anlaşılmaktadır. Bu noktadan hareketle bu çalışmada RFM metrikleri temelinde müşterilerin kümelerine ayrılması ve pazarlama bakış açısıyla yorumlanması amaçlanmıştır. Dolayısıyla bu amacı gerçekleştirmek için Karaman bölgesinde faaliyet gösteren bir gıda perakende işletmesinden veriler elde edilmiştir. Bu verilerin analizinde RFM ve k-ortalama teknikleri kullanılmıştır. Yapılan analiz sonucu toplamda 6 müşteri kümesi oluşmuştur. En karlı müşteri 3 numaralı müşteri kümesi iken, en karsız ve neredeyse terk etmek üzere olan müşteri kitlesi 1 ve 6 numaralı müşteri kümeleri olmuştur.

Anahtar kelimeler: Müşteri Bölümlendirme, RFM, K-ortalama, Kümeleme

Abstract

In parallel with the change and development of macro factors in the world, a transition period from mass marketing understanding to customer-oriented understanding has been experienced in marketing. Undoubtedly, one of the most important issues in this process is customer segmentation. Because of the customer-oriented marketing approach of customer segmentation, it can play an important function in the classification and clustering of customers within the framework of various parameters. In the literature, parallel to the developments in practice, it is observed that the interest in this subject has increased and the studies have been enriched. However, it is understood that the studies on this subject are still limited. From this point of view, this study aims to divide customers into clusters on the basis of RFM metrics and to interpret them from a marketing perspective. Therefore, data was obtained from a food retail business operating in the Karaman region to achieve this goal. RFM and k-mean techniques were used in the analysis of these data. As a result of the analysis, a total of 6 customer clusters were formed. While the

Önerilen Atıf /Suggested Citation

Tuncer, İ., Karaboğa, K. 2021, RFM Metriklerini Kullanarak Kümeleme Yöntemi ile Müşteri Bölümlendirme: Perakende Sektöründe Bir Uygulama, *Üçüncü Sektör Sosyal Ekonomi Dergisi*, 56(1), 411-425

most profitable customer was the number 3 customer cluster, the most unprofitable and almost abandoned customer clusters were the number 1 and 6 customer clusters.

Keywords: Customer Segmentation, RFM, K-mean, Clustering

Giriş

Günümüzde bilgisayar, internet ve veri tabanı teknolojilerinin gelişmesi her düzeyde işletmenin müşterileri hakkında demografik, ekonomik ve davranışsal birçok veriyi kayıt altına alması ve büyük hacimdeki verilere sahip olmasına olanak tanımıştır. Müşteriler hakkında daha fazla bilginin veri tabanlarında kaydedilmesi sonucunda “veri madenciliği ve dolayısıyla müşteri bölümlendirme” uygulamaları perakende sektöründe sıklıkla kullanılan alanların başında gelmektedir (Han vd., 2011). Çünkü müşteriler ve işletme süreçleri dikkate alındığında “satış, tüketim, taşımacılık, yeniden teslimat” (Anitha ve Patil, 2019) ve benzeri birçok operasyonel süreçlere ilişkin verileri kaydetmek ve bunları işlemek istatistik, veri madenciliği algoritmaları ve bilgisayar teknolojileri ile oldukça kolay olabilmektedir. Perakende sektöründe veri madenciliği algoritmalarının kullanımı ticari işlemlerin tüm yaşam döngüsü boyunca müşteri davranışını ve ilgili kalıpları belirlemeye ve etkin bir şekilde haritalamaya yardımcı olur. Sonuç itibarı ile veri madenciliği yöntemleri -en çok kullanılan yöntemlerden müşteri bölümlendirme analizleri- müşteri hizmetlerinin iyileştirilmesine, etkili satış ve dağıtım stratejilerinin geliştirilmesine ve çok daha fazlasına imkan sağlar. Müşteri bölümlendirme analizleri, istatistiksel sonuçlara ve göstergelere dayanarak perakende sektöründeki işletmelerin promosyon kampanyaları, dönemsel indirimleri genişletme veya çapraz satış gibi çeşitli satış ve pazarlama stratejileri tasarlayarak kuponların satışları artırmasını ve müşteri elde tutma oranını artırmasını sağlayabilir (Han vd., 2011).

Bu çalışma Karaman ilinde faaliyet gösteren yerel bir perakende işletmesinin geçmiş müşteri satına alma verilerini dikkate alarak müşteri bölümlendirme yapmayı ve buna göre sadık ve karlı müşteri gruplarını belirlemeyi amaçlamaktadır. Bu müşteri bölümlendirme sonucunda ortaya çıkan müşteri gruplarına farklı kampanya ve satış tutundurma çabalarının geliştirmesi sağlanarak satış ve karlılığın artırılması hedeflenmektedir. Müşteri bölümlendirmeyi gerçekleştirebilmek için RFM metriklerinden hareketle K-ortalama kümeleme analizleri kullanılmaktadır. Bu çalışmada müşteri bölümlendirme kavramı açıklandıktan sonra RFM ve K-ortalama yöntemi ile kümeleme analizi hakkında bilgi verilmektedir. Ayrıca gerçek perakende verileri üzerinden müşteri bölümlendirme analiz sonuçları raporlanarak perakende işletmesine yönelik olası kampanya önerileri sunulmaktadır. Çalışmanın, RFM ve K-ortalama yöntemleri ile müşteri bölümlendirmeyi gerçekleştirmesi bakımından ulusal alan yazına katkı sağlaması beklenmektedir.

Müşteri Bölümlendirme

Müşterilerin ihtiyaç ve istekleri çeşitli faktörler nedeniyle farklılaşabilmektedir. Dolayısıyla bu farklılık tüketicilerin satın alma davranışlarına yansımakta ve tüketiciler işletmelerden farklı hizmet veya ürün beklentileri içinde girebilmektedir. İşletme yöneticileri bu soruna çözüm üretebilmek için müşteri bölümlendirmeye başvurabilmektedir (Serhat vd., 2017). Çünkü müşteri bölümlendirme benzer müşterileri gruplamak için birleştirir veya bir müşteriyi diğerinden farklı kılan özelliklerine göre ayırır (Hiziroğlu, 2013; Jenkinson, 1994). Bu kavram ilk olarak Smith (1956) tarafından ortaya konmuştur ve birçok bilimsel araştırmayla desteklenerek pratikte de başarıyla uygulanmıştır. O zaman beri, çevrimiçi verilerin artmasıyla birlikte müşteri bölümlendirme bilimsel olarak sürekli bir araştırma alanı haline gelmiştir (An vd., 2018; Bonoma ve Shapiro, 1984). Dolayısıyla günümüzde dijitalleşmeyle birlikte büyük verinin ortaya çıkması bu konuyu daha da önemli haline getirdiğini ifade edebiliriz.

Geleneksel pazarlarda müşteri bölümlendirme, pazarlama çalışmalarında kullanılan en önemli yöntemlerden biridir (Chan, 2008). Çünkü müşteri bölümlendirme, işletmelerin farklı müşteri kitlelerinin belirli sınıflara ayrılmasında yardımcı olan etkili bir yaklaşımdır. Bu etkili yaklaşım farklı müşteri gruplarına uygun pazarlama stratejileri geliştirmek ve her bir kümenin ihtiyaç ve

istekleri temelinde ürün veya hizmet sunmak için uygulanabilmektedir. Dahası müşteri bölümlendirme uygulamak işletmelerin verimli ve optimum kaynak tahsis etmesini sağlayabilmektedir (Khalili-Damghani vd., 2018). Ayrıca, bölümlendirme işletmelere hangi müşterilerinin daha karlı ve sadık olduğu konusunda öngörüler sunmakta ve işletmelerin bu duruma göre strateji geliştirmesine olanak sağlayabilmektedir (Dursun ve Caber, 2016). Örneğin, “A” müşterisinin “X” perakendecisinden geçmişte yüksek değerli alışveriş eylemi bulunmaktadır, ancak son zamanda alışveriş yapmadığı tespit edilmiştir. Dolayısıyla bölümlendirme kayıp edilmek üzere olan müşterileri tekrar kazanabilme imkânı sunacaktır. Dahası, bölümlendirme farklı gruplara farklı pazarlama iletişim faaliyetleri gerçekleştirilmesini sağlayarak kampanya yönetim maliyetlerinin azaltılmasına olanak tanımaktadır (Kotler, 1967).

İşletmeler müşteri bölümlendirmede birçok parametre kullanılabilmektedir. Genel olarak bölümlendirme demografik, psikografik ve davranışsal olmak üzere üç ana bölüm üzerinden gerçekleştirilmektedir (Kotler, 2003). Daha spesifik olarak kullanılan en yaygın özellikler ise konum, yaş, cinsiyet, gelir, yaşam tarzı ve önceki satın alma davranışlarıdır (Christy vd., 2018). Bu çalışmada ise müşterinin satın alma davranışlarına dayalı bir bölümlendirme gerçekleştirilecektir.

RFM Analizi

Müşteri odaklı pazarlama stratejisi, müşteriler ile işletme arasındaki ilişkileri güçlendirmeye yardımcı olması bakımından önemlidir. Bu strateji ile müşteri özelliklerini keşfetmek ve müşteri gereksinimlerini karşılamak, müşteri sadakatini artırırken işletme operasyonlarındaki riskin de en aza indirilmesine katkı sağlayarak karlılığı artırır (Cheng ve Chen, 2009). Müşteri özelliklerini keşfetmek ve müşterileri bu özelliklere göre bölümlere ayırmak müşteri odaklı politikaların geliştirilmesi bakımından önemlidir. Müşteri bölümlendirme ve kümeleme teknikleri farklı müşteri gruplarının satın alma davranışlarını keşfedebilmek için yaygın olarak kullanılmaktadır (Chang ve Tsai, 2011; Wu ve Lin, 2005; Yeh vd., 2009). RFM analizi müşteri bölümleri oluşturarak müşterilerin işletme karlılığına katkılarını ölçümleyebilen bir tekniktir (Chang ve Tsai, 2011; Wu ve Lin, 2005).

RFM analizi, İngilizce “Recency, Frequency ve Money” kelimelerinin kısaltması (RFM) şeklinde ifade edilen bir müşteri bölümlendirme analizi algoritmasıdır. RFM yani Güncellik/Sıklık/Parasal Değer (RFM) analizi müşteri ilişkileri yönetimi ve veri tabanı pazarlamasında kullanılan literatürde kabul görmüş bir yöntemdir. RFM analizi 1994 yılında Hughes tarafından geliştirilmiştir. Bu yöntemin çevrimiçi satın alma ve perakendecilik gibi birçok müşteri bulunan sektörlerde oldukça yaygın kullanım alanı bulunmaktadır. Bu yöntem son satın alma tarihi, alışveriş sıklığı ve harcanan parasal değer temelinde müşterileri geçmiş işlem hacimlerinden harekete gruplara ayırmaktadır (Christy vd., 2018). Dolayısıyla bu parametreler çerçevesinde gruplara ayrılan müşterilerin gelecek davranışları hakkında öngörüler oluşturulabilmektedir. Böylelikle farklı gruplardaki müşterilere kişiselleştirilmiş stratejiler uygulanabilmektedir (Wei vd., 2013).

RFM Modelinin Tanımı: 1994 yılında Hughes tarafından önerilen RFM analizi “müşteri tüketim güncel tarih aralığı, satın alma sıklığı ve tüketim harcama değerleri” değişkenlerini dikkate alarak bu üç öznelik temelinde büyük müşteri verilerinden hareketle müşteri bölümlendirme yapmaya yardımcı olan bir yöntemdir. RFM analizinin uygulama adımları ve detayları aşağıdaki gibi açıklanabilir (Cheng ve Chen, 2009);

1. Son Satın Alma İşleminin Güncelliği (R): “R” tüketici tarafından en son yapılan alışı ile inceleme zamanı arasındaki aralığı ifade etmektedir. Aralık ne kadar kısa olursa R’nin o kadar büyük olur. Çünkü Tüketicinin yakın bir tarihte işletmeden alışveriş yapmış olması istenilen bir durumdur.
2. Satın Alma Sıklığı (F): Belirli bir tarih aralığındaki (dönemdeki) satın alma işleminin tekrar etme sayısıdır. Örneğin bir hafta üç kez, bir ayda dört kez yada bir yılda yirmi kez gibi. Sıklık ne kadar çoksa “F” o kadar büyük olur.

3. Satın Almaların Parasal Değeri (M): “M” belirli bir dönemdeki harcamaların parasal miktarını temsil eden değişkendir. Harcama tutarı ne kadar büyükse “M” o kadar büyük olur.

Bu değişkenlerden “Parasal Değer” değişkeni “Güncellik” ve “Sıklık” değişkenlerinden nitelik olarak çok farklı değerler alabildiğinden bu değer normalleştirilerek kullanılması gerekebilir. Burada kullanılabilecek “*min-maks normalizasyon yöntemi*” formülü aşağıdaki gibidir (Monalisa vd., 2019);

$$X_{norm} = \frac{X_i - X_{min}}{X_{mak} - X_{min}}$$

Wu ve Lin (2005)’e göre RFM analizindeki R, F ve M değeri büyük olan müşterilerin ilgili işletmeden yeniden alışveriş yapma olasılığının o kadar yüksek olması beklenir. “Sıklık” değeri ne kadar büyükse, işletmenin müşterileri o kadar sadık müşteridir (Christy vd., 2018). Tüm bu hesaplama ve müşteri bölümlendirme yapmaya olanak tanınması bakımından RFM yöntemi çok etkili bir yöntemdir (Cheng ve Chen, 2009; Frederick, 1997).

RFM analizinde araştırma modelini oluşturan bu üç öznitelik temel alınarak her bir simgeye genellikle 1 ile 5 arasında bazen ise 1 ile 9 arasında bir sayısal değer ataması yapılır. Müşterilerden en üstteki beşte birine 5 puan ve diğerlerine 4, 3, 2 ve 1 değerlerinden birisi verilir. Sonuç itibari ile her bir müşteriye 555, 554, ... 111 aralığında bir genel puan ataması yapılır. Bu genel puanlar her bir öznitelikten alınan puanların yan yana getirilmesi ile elde edilir. 555 puana sahip müşteriler, işletmeye daha fazla getiri sağlama olasılıkları yüksek olduğu için işletmenin potansiyel ve sadık müşterileri olarak adlandırılabilir. 111 puana sahip müşteri grubu ise işletme ile uzun zaman önce bağını koparmış olan kaybedilmiş müşteri bölümlerini gösterir. Bu RFM puanına bağlı olarak, her müşteri farklı bir bölümlere yerleştirilebilir.

K-ortalama Kümeleme Yöntemi

Bu çalışmada iki aşamalı kümeleme analizi yapılmıştır. Bunlardan ilki RFM skorları aracılığı ile oluşturulan kümeler ve bu kümelerle ait skorlardır. İkinci aşama ise RFM genel skorlarından hareketle K-ortalama yöntemi kullanılarak yeni bir bölümlendirme yapılmıştır. Bu yöntemlerden K-ortalama yöntemini açıklamadan önce kümeleme analizinin ne olduğu ve niçin kullanıldığının açıklanması gerekebilir. Kümeleme analizi, sıkça kullanılan veri madenciliği yöntemlerinde birisi olup denetlenemeyen örüntü tanımaya yönelik analiz yöntemlerinden birisidir. Buradaki denetleme bakış açısı verilerin analiz öncesinde etiketlenmemiş (kategorizasyon yapılmamış) olmasına dayalıdır.

Kümelemenin amacı verilerde yapı bulmaktır ve bu nedenle doğası gereği keşfedicidir (Jain, 2010). Kümeleme analizi, bir gruptaki örneklerin benzerlik/farklılık ilişki ölçüsüne göre birkaç kümeye otomatik olarak atanması işlemidir. Bir küme analizi için girdi: bir grup numune ve iki numune arasındaki benzerlik (veya farklılık) ölçüsüdür. Bir kümenin diğerine ne kadar yakın veya uzak olduğunu bulmak için, diğer benzerlik ölçümlerinde uygulanabilen Öklid mesafesini, Mahalanobis ve Manhattan algoritmaları kullanılabilir. Örneğin; kümeleme analizinin yararlı bir uygulaması, işletmeler için pazarda bulunan farklı müşteri kümelerinin veriye dayalı olarak belirlenmesidir. Pazardaki tüketici kümelerinin alt kümelerinin her birine farklı pazarlama stratejilerinin uygulanabilmesi için kümeleme analizinden yararlanılabilir. Bu, bir kümedeki müşterilerin satın alma modellerindeki farkı diğer kümedeki müşterilere göre gözlemleyerek müşterilerin kümeleme kalitesini bulmaya yardımcı olacaktır (Karaboğa, 2020; Mishra vd., 2016). Kümeleme analizi literatürde sıklıkla kullanılan, sayısız kullanım alanı olan ve çok sayıda yayınlanmış algoritması olan bir veri madenciliği yöntemidir. Kümeleme analizinde sıklıkla kullanılan yöntemlerden birisi de K-means (K-ortalama) algoritmalarıdır. K-ortalama algoritmaları ilk olarak 1955 yılında yayınlanmıştır. K-ortalamlarının 50 yıl önce önerilmiş olmasına ve o zamandan beri binlerce kümeleme algoritmasının yayımlanmış olmasına rağmen, K-ortalamları hala yaygın olarak kullanılmaktadır. Bu yöntem, psikoloji, biyoloji ve pazarlama araştırması gibi çok çeşitli disiplinlerde yaygın olarak kullanılmaktadır (Jain, 2010; Moradpour

ve Long, 2019; Zhu vd., 2017). K-ortalama kümeleme analizleri pazarlama araştırması alanında, müşterilerin gruplanması ile işgücü yönetimi ve planlaması gibi alanlarda kullanılmaktadır (Arabie ve Hubert, 1994).

K- ortalama kümeleme yönteminde küme sayısının (k) belirlenmesi dört aşamadan oluşur (Jain, 2010);

1. Başlangıçtaki küme sayısının (k) belirlenmesi,
2. En yakın kümeye desen atanması (küme sayısı kadar küme merkezlerinin belirlenmesi),
3. Hata karelerinin toplamının hesaplanması (her kümeye ortalama merkezi değer hesaplaması),
4. Hata karelerinin küme toplamı stabilize olana kadar 2. ve 3. aşamaların tekrarlanması (kümelere nihai atamanın yapılması).

Öklid tipi uzaklık fonksiyonuna göre heaplama denklemi aşağıdaki gibidir (Rençber, 2019);

$$d(i, j) = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2}$$

K-ortalamlar yönteminin temel amacı; yukarıdaki hata fonksiyonunun minimum hale getirmektir. Her iterasyonda bu değerin azalması beklenmektedir. Sonuç itibari ile en küçük hatanın elde edildiği düzeyde nihai kümeleme ataması meydana gelmektedir (Rençber, 2019; Wang ve Zatzick, 2019). Bu çalışmada RFM skorları ile elde edilmiş olan verilere K-ortalama algoritması kullanılarak iki aşamalı kümeleme analizi gerçekleştirilmiştir.

Uygulama

Bu çalışmada işletmelerin çeşitli stratejiler geliştirebilmesi için RFM metrikleri çerçevesinde perakende sektöründe faaliyet gösteren müşterilerin bölümlendirmesi amaçlanmıştır. Bu bağlamda veriler, Karaman ilinde perakende sektöründe faaliyet gösteren bir alışveriş merkezinden elde edilmiştir. Veri 6600 adet müşteriyle ilgili “satın alma sıklığı”, “en son alışveriş yaptığı tarih” ve “toplam sepet tutarı” bilgilerini içermektedir. Bu ikincil veriler, Ocak 2019 - Kasım 2020 tarihleri arasındaki işlemleri kapsamaktadır. Bu veriler talep edilmeden önce istenilecek bilgilere ilişkin form etik kuruluna sunulmuş olup, etik kurulu onayı alındıktan sonra veriler elde edilmiştir. Bu verileri ilişkin bir kesit Tablo 1’de sunulmuştur.

İlk olarak verilerin analiz öncesi kontrolü, düzenlenmesi ve eksik verilerin silinmesi işlemi gerçekleştirilmiştir. Daha sonra ise analiz aşamasına geçilmiştir. Bu verilere ilişkin analiz iki aşamadan oluşmaktadır. İlk aşamada müşterilerin güncellik, sıklık ve parasallık metriklerine ilişkin bilgiler kullanılarak RFM analizi yapılmış ve böylelikle her bir müşterinin RFM skoruna ulaşılmıştır. RFM skorları çerçevesinde müşteriler bölümlere ayrılmıştır. İkinci aşamada ise RFM metrikleriyle oluşan skorlar bir veri kabul edilip, bu değerler çerçevesinde K-ortalama yöntemi ile müşteriler kümelere ayrılarak ikinci bir bölümlendirme gerçekleştirilmiştir. Bu verilerin analizinde SPSS 22 ve R Programları kullanılmıştır.

Tablo 1: RFM metriklerine ilişkin değerler

Musteri ID	R	F	M
1	555	3	210,06
2	31	13	360,71
3	604	18	339,81
4	555	2	84,45
5	109	326	6876,38
6	73	11	759,03
.	.	.	.
.	.	.	.
6595	187	11	325,2

6596	139	4	397,42
6597	139	5	499,03
6598	307	1	63,24
6599	30	108	4182,63
6600	65	9	461,36

Not : R= *Gün*, F=*Alışveriş Sıklığı*, M= *TL cinsinden sepet değeri*

Bulgular

Bu kısımda eldeki verilerin RFM ve k-ortalama yöntemleri ile analizi sonucunda elde edilen bulgular sunulmuştur.

RFM Analiz Bulguları

RFM analizinde her bir müşteri için güncellik, sıklık ve parasallık değerleri kullanılmaktadır. Her bir müşteri aldığı değerler çerçevesinde puanlanmaktadır. Bu çalışmada puanlama sistemi 5’li olarak belirlenmiştir. Yani analiz sonucunda her bir müşteri güncellik, sıklık ve parasallık değerleri çerçevesinde 1’den 5’e kadar puan alabilecektir. “1” en düşük puan iken “5” en yüksek puandır. RFM analizinin uygulanması sonucunda her bir müşterinin R-F-M değerlerine atanan puan ve bunun sonucu oluşan RFM skorları Tablo 2’de sunulmuştur. Müşteri sayısı fazla olduğu için analiz sonucuna ilişkin küçük bir kesit sunulmuştur. RFM analiz bulguları incelendiğinde bazı müşterilerin oldukça karlı müşteri olduğu gözlemlenirken bazı müşterilerin ise artık terk ettiği ifade edilebilir. Örneğin, 5 numaralı müşterinin satın alma sıklığı ve sepet değeri yüksek skora sahip iken güncelliği orta skor almıştır. Ayrıca, Bakker (2020) her biri birden çok R, F, M kombinasyonuna karşılık gelen 10 farklı müşteri bölümü önermiştir. Bu 10 farklı müşteri bölümlendirmesi şu şekilde ifade edilmiştir (Bakker, 2020);

**Şampiyonlar:* son zamanlarda satın almış, sık sık satın almış ve sepet değeri oldukça yüksektir (Skor: R= 4-5, FM= 4-5),

**Sadık müşteriler:* düzenli olarak satın alırlar ve promosyonlara karşı duyarlıdır (Skor: R= 2-5, FM= 3-5),

**Potansiyel sadık:* ortalama satın alma sıklığına sahip yeni müşterilerdir (Skor: R= 3-5, FM= 1-3),

**Yeni müşteriler:* güncellik değerleri iyi ancak çok sık satın alma eylemleri yoktur (Skor: R= 4-5, FM= 0-1),

**Umut verici:* güncellik değerleri oldukça iyi ancak sepet skorları biraz düşüktür (Skor: R= 3-4, FM= 0-1),

**Dikkat edilmesi gerekenler:* yakın zamanda satın alım oranı alışveriş sıklığına ve sepet değerine göre daha iyi, ancak güncelliğe dikkat edilmesi gerekir (Skor: R= 2-3, FM= 2-3),

**Uyumak üzere:* güncellik değerleri ve alışveriş sıklığı ortalamanın altındadır. Dolayısıyla etkinleştirilmesi için teşvik edilmelidir (Skor: R= 2-3, FM= 0-2),

**Risk altında:* son satın alma güncellik skoru düşüktür, dolayısıyla alışverişe teşvik edilmeli (Skor: R= 0-2, FM= 2-5),

**Onları kaybedemezsin:* satın alma sıklıkları oldukça yüksek bir grup ancak bir süredir güncellik skorları düşüktür (Skor: R= 0-1, FM= 4-5).

**Uykuda:* bir süredir güncellik değeri ve satın alma sıklığı oldukça düşük skorları sahip, her an kaybolabilir (Skor: R= 1-2, FM= 1-2).

Yukarıdaki müşteri bölümlendirme türleri her bir müşterinin R, F ve M skorlarının kombinasyonları çerçevesinde R programı ile atanmış ve Tablo 2’de sunulmuştur. Örneğin, bu tabloda “112” RFM skoruna “uykuda” şeklinde nitelendirilen müşteri bölümlendirme türü atanırken, “142” RFM skoru bulunan müşterinin “risk altında” şeklinde nitelendirildiği


gözlemlenmektedir. Bu çalışmada amaç doğrudan RFM skorlarına göre bölümlendirme olmadığı için derinlemesine tartışılmamıştır.

Tablo 2: RFM Skorları

Müşteri	G. Skor	S. Skor	P. Skor	RFM Skor	Küme	Bölümlendirme
1	1	1	2	112	1	Uvkuda
2	5	3	2	532	2	Potansiyel sadık
3	1	4	2	142	6	Risk altında
4	1	1	1	111	1	Uvkuda
5	3	5	5	355	3	Sadık müşteriler
6	4	3	3	433	2	Potansiyel sadık
7	2	2	2	222	6	Uvkuda
8	1	1	1	111	1	Uvkuda
9	5	5	5	555	3	Şampiyonlar
.	.	.	.	.	.	.
6592	5	5	4	554	3	Şampiyonlar
6593	3	5	5	355	3	Sadık müşteriler
6594	4	3	3	433	4	Potansiyel sadık
6595	2	3	2	232	6	Risk altında
6596	3	2	2	322	4	Uyumak üzere
6597	3	2	3	323	4	Uyumak üzere
6598	2	1	1	211	1	Uvkuda
6599	5	5	5	555	3	Şampiyonlar
6600	4	3	3	433	4	Potansiyel sadık

RFM Metriklerine Göre Kümeleme Analizi ve Bulguları

Bu aşamada müşterilerin RFM skorlarına temelinde gruplandırmak için kümeleme algoritmalarından biri olan k-ortalama metodu ile analiz yapılmıştır. Bu analizin ilk aşamasında k-ortalama metodunda kullanılması gereken küme sayısının belirlenmesi gerekmektedir. Küme sayısını belirlemede dirsek metodu (Elbow Metodu) kullanılmıştır. Bu metod ile k adet küme merkezi ile yürütülmesi tamamlanmış algoritma sonucunda, her bir k kümesine ait karesel hata oranı değerleri grafik eğrisinde sunulmuştur. Dolayısıyla bu eğri vasıtasıyla keskin bir düşüşün ve sonrasında sabit orantılı bir düşüşün olduğu nokta tespit edilebilmektedir. Bu tespit sonucunda k-ortalama metodunu uygularken kullanacağımız optimum veri küme sayısı belirlenmiş olacaktır (Zabinsky, 2011). Dirsek metodu veri üzerinde R programıyla çalıştırılmış ve Şekil 1'deki grafik elde edilmiştir.



Şekil 1: Dirsek Metodu Sonuçları

Şekil 1'deki grafik incelendiğinde 6. kümeye kadar karesel hata oranının hızlı bir şekilde eğim gösterdiği sonrasında ise eğilim yataya yakın seyrettiği gözlemlenmektedir. Dolayısıyla bu eğride optimum küme sayısının 6 olduğu gözlemlenmektedir. Eğer 6'dan sonraki kümeler optimum küme olarak belirlenirse modelin yorumlanabilirliğini tehlikeye atabilecektir.

Dirsek metoduyla k-ortalama kümeleme metodunun en uygun küme sayısı belirlendikten sonra R programıyla müşteri RFM skorları temelinde K-ortalama metodu çalıştırılmıştır. Bu metodun uygulanması sonucu oluşan kümeleme değerleri Tablo 3'de sunulmuştur. Bu tabloda aynı zamanda RFM skorlarına göre yapılan bölümlendirme sunulmuştur. Yani, her bir kümede RFM skorlarına göre oluşan bölümlendirmede ne kadar müşteri bulunduğuna yönelik ayrıntılı bilgi sunulmuştur.

Tablo 3: K-ortalama kümeleme bulguları

Küme	Müşteri	Sayı
1	Uyumak üzere	108
	Risk altında	5
	Uykuda	1103
2	Şampiyonlar	407
	Sadık müşteriler	584
	Dikkat edilmesi gerekenler	8
	Potansiyel sadık	288
3	Onları kaybedemezsin	5
	Şampiyonlar	698
	Sadık müşteriler	353
4	Uyumak üzere	265
	Risk altında	3
	Şampiyonlar	2
	Uykuda	4
	Sadık müşteriler	23
	Dikkat edilmesi gerekenler	167
	Yeni müşteriler	33
	Potansiyel sadık	302
	Umut verici	73

5	Uyumak üzere	38
	Risk altında	338
	Onları kaybedemezsin	69
	Uykuda	21
	Sadık müşteriler	317
	Dikkat edilmesi gerekenler	221
	Potansiyel sadık	1
6	Uyumak üzere	44
	Risk altında	393
	Uykuda	698
	Sadık müşteriler	1
	Dikkat edilmesi gerekenler	28

Ayrıca, R programı ile her bir kümeye ilişkin güncellik, sıklık ve parasal değerlerin ortalamaları, toplam müşteri adedi hesaplanarak Tablo 4'te sunulmuştur.

Tablo 4: Kümelere İlişkin Değerler

Küm e	Güncellik			Sıklık			Parasallık		
	Ortala ma	Müşte ri adedi	Topla m	Ortala ma	Müşte ri adedi	Topla m	Ortala ma	Müşte ri adedi	Toplam
1	437,72	1216	53227 7	2,06	1216	2515	132,11	1216	160647 ,8
2	47,00	1287	60500	21,67	1287	27900	1174,3 0	1287	151140 8
3	41,91	1056	44260	88,76	1056	93733	4724,8 9	1056	498949 3
4	88,16	872	76884	6,07	872	5301	285,79 1	872	249210 ,4
5	202,18	1005	20319 9	19,10	1005	19202	1330,9 7	1005	133763 0
6	393,25	1164	45774 9	6,24	1164	7264	445,09	1164	518090 ,5

Tablo 4'deki değerleri incelediğimizde en karlı müşterilerin 3. kümede toplandığını ifade edebiliriz. Çünkü ortalama güncellik değerinin oldukça yakın tarih olduğunu, sıklık düzeyinin diğer kümelere göre açık ara daha yüksek olduğunu ve ortalama sepet tutarının diğer kümelere daha yüksek olduğunu söyleyebiliriz. Dolayısıyla bu işletme için en sadık müşteri grubudur. Bu işletme için 2. karlı müşteri grubu ise 2 numaralı kümedir. Ne kadar 5 numaralı kümeye göre parasallık değeri kısmen düşük olsa da müşterilerin güncellik ve sıklık düzeyi oldukça yüksektir. Ancak, Tablo 3'deki RFM skorlarına göre bölümlendirme müşteri sayılarını incelediğimizde potansiyel sadık müşteri sayısının önemli olduğu ve işletmenin bu müşterileri sadık hale getirmesi 2 numaralı kümedeki müşterilerin ortalama parasallık değerini artıracaktır. Diğer taraftan, tablo 3'deki değerlere göre 6 kümeden en zayıf halkanın 1 numaralı kümeyi oluşturan müşteri kitlesidir. Diğer kümeler ile karşılaştırıldığında her bir değişken değerinin diğerlerine göre düşük olduğu anlaşılmaktadır. Dolayısıyla işletme için en karsız müşteri grubunu oluşturmaktadır.

Tartışma ve Sonuç

Bu çalışmada RFM metrikleriyle k-ortalama algoritması kullanılarak müşterilerin bölümlendirmesi gerçekleştirilerek özellikle ulusal literatürdeki boşluğa katkı sunulması amaçlanmıştır. Dolayısıyla bu çalışmada yapılan analizler ve elde edilen bulgular çerçevesinde bu amacın gerçekleştirildiği ifade edilebilir. Çalışmanın, hem teorik hem de uygulayıcılara önemli katkılar sunması beklenmektedir.

Özellikle kitlesel pazarlama anlayışından sonra daha çok müşteri odaklı bir pazarlama anlayışına geçilmesi müşteri bölümlendirmesinin önemi oldukça artırmıştır. Dolayısıyla bilimsel olarak bu konunun irdelenmesi oldukça önemlidir. Bu noktadan hareketle çalışmada 6600 müşteriye ait satış bilgileri çerçevesinde RFM metrikleri kullanılarak müşteriler kümelerine ayrılmış ve müşteri bölümlendirmesi gerçekleştirilmiştir. Bu analiz sonucu işletme yöneticilerine yön gösterebilecek birçok bulguya ulaşılmıştır. Dolayısıyla büyük resmi görme adına işletmeye önemli fırsatlar sunmaktadır. Bu bulgular işletmenin 6600 müşterisi içerisinde en karlı müşterileri tespit edebilme imkanı vermiştir. Dolayısıyla bu bulgular ışığında ilgili perakende işletmesi karlı müşterilerine daha fazla odaklanmalıdır. Çünkü işletmeye en fazla karı getiren bu kitledir. Dahası, bulgular riskli, kaybedilmiş müşteri gibi grupları da işaret etmektedir. Bu bulgular işletmenin bu müşterileri tekrar kazanma adına işletmenin yeniden stratejiler geliştirmesi gerektiğini göstermektedir. Tablo 4'deki kümelerle ilişkin ortalama RFM değerleri incelendiğinde verilerini aldığımız müşterilerle ilgili çeşitli çıkarımlarda bulunulabilmektedir. Güncellik değerleri incelendiğinde mevcut müşterilerin yarısının satın alma tarihinin oldukça iyi olduğu ancak diğer yarısındaki ortalamanın neredeyse 1 yıla yakındır alışveriş yapmadığını anlaşılmaktadır. Dolayısıyla bu işletme için oldukça riskli bir durumu göstermektedir. İşletmeler pasif müşterilerinin tekrar satın almasını sağlamak adına çeşitli kampanya stratejileri geliştirmesi bu riskin en asgari düzeye inmesine fayda sağlayabilecektir. Satın alma sıklığında ise daha kötü bir durum söz konusudur. 3 numaralı kümedeki müşterilerin oldukça iyi bir satın alma sıklığı söz konusu iken diğer kümelerle ait müşterilerin satın alma sıklıklarının oldukça düşük olduğu gözlemlenmektedir. Dolayısıyla işletme yöneticileri bu durumu pozitif çekmeye yönelik çeşitli kampanya stratejileri geliştirebilir. Böylelikle müşterilerin satın alma sıklığı artırılarak karlı müşteri yüzdesi artırılabilir. Kümelerin parasallık ortalama değerleri incelendiğinde ise 3 numaralı kümenin değerlerinin diğer kümelerin değerlerinden oldukça iyi olduğu gözlemlenmektedir. En sadık müşteri grubunun 3 numaralı müşteriler olduğunu ifade edebiliriz. Diğer yandan 1 ve 6 numaralı kümelerin ortalama parasallık değerlerinin çok düşük olduğunu ve RFM değerlerinin bütününe düşündüğümüzde bu kümelerin kayıp müşteri grubu olduğunu ifade edebiliriz. Bu oran yaklaşık toplam müşterinin % 30'unu oluşturmaktadır. Dolayısıyla işletme yöneticilerinin bu konuyu oldukça detaylı inceleyerek bu müşterilerin neden kaybedildiğini araştırmasının işletmenin sürdürülebilir karlılığı için önemli bir adım olacağını ifade edebiliriz.

Bu çalışma aynı zamanda literatüre birtakım katkılar sunmaktadır. İlgili literatürü incelediğimizde bizim bilgilerimize göre müşteri bölümlendirmesine yönelik bilimsel çalışmaların daha çok bölümlendirme analiz yöntemlerine odaklandığını (Ör: Christy vd., 2018; Dogan vd., 2018; Kabasakal, 2020) ve pazarlama bakış açısıyla kısıtlı çalışmanın ortaya konulduğunu söyleyebiliriz. Dolayısıyla bu çalışma pazarlama bakış açısıyla değerlendirilmesi nedeniyle literatürün zenginleşmesine katkı sağlayacaktır. Ayrıca bu çalışmada ilk aşamada RFM skorları çerçevesinde birinci basamak bir kümeleme gerçekleştirilmiş olup daha sonrasında k-ortalama ile ikinci basamak kümeleme analizi yapılmıştır. K-ortama ile yapılan analizde RFM ile yapılan kümeleme türleri detaylı verilerek farklı bir bakış açısı ortaya konmuştur. Literatür incelememize göre bu yaklaşımın ulusal alan yazında ilk olduğunu ifade edebiliriz. Bu detay özellikle pazarlama stratejileri oluşturmada önemli ipuçları sağlayabilir. Dahası ulusal literatürü incelediğimizde bu tür çalışmaların kısıtlı olduğu göze çarpmaktadır. Dolayısıyla ulusal literatürün zenginleşmesine de önemli katkılar sunabilecektir. Diğer taraftan bu çalışmada bazı kısıtlar bulunmaktadır. İlk olarak, bu çalışmada veriler bir ilde bulunan gıda alışveriş işletmesinden elde edilmiştir. Dolayısıyla gelecek çalışmalarda farklı sektörler ve daha büyük veriler ile çalışılması pazarlama

perspektifiyle bakış açısının zenginleşmesini sağlayacaktır. İkinci olarak, bu çalışmaya ait verilerde demografik bilgiler yer almamaktadır. Gelecek çalışmalarda demografik bilgilerinde metriklere eklenmesi satın alma davranışlarının daha derinlemesine analiz edilmesine katkı sağlayacaktır. Son olarak ise bu çalışmada kümeleme yöntemi olarak k-ortalama yöntemi kullanılmıştır. Gelecek çalışmalarda farklı yöntemler kullanılarak kıyaslama gerçekleştirilebilir. Özellikle pazarlama stratejileri çerçevesinde farklı öngörüler sunabilecek bulgular sağlayıp sağlamadığı test edilebilir.

Kaynakça

- An, J., Kwak, H., Jung, S., Salminen, J., & Jansen, B. J. (2018). Customer segmentation using online platforms: isolating behavioral and demographic segments for persona creation via aggregated user data. *Social Network Analysis and Mining*, 8(1), 54.
<https://doi.org/10.1007/s13278-018-0531-0>
- Anitha, P., & Patil, M. M. (2019). RFM model for customer purchase behavior using K-Means algorithm. *Journal of King Saud University-Computer and Information Sciences*.
- Arabie, P., & Hubert, L. (1994). Cluster analysis in marketing research. İçinde R. P. Bagozzi (Ed.), *Advanced methods of marketing research* (ss. 160–189). Blackwell.
- Bakker, L. A. (2020). Know your customers with RFM. *Futurice*.
<https://futurice.com/blog/know-your-customers-with-rfm>
- Bonoma, T. V., & Shapiro, B. P. (1984). Evaluating market segmentation approaches. *Industrial Marketing Management*, 13(4), 257–268.
- Chan, C. C. H. (2008). Intelligent value-based customer segmentation method for campaign management: A case study of automobile retailer. *Expert systems with applications*, 34(4), 2754–2762.
- Chang, H.-C., & Tsai, H.-P. (2011). Group RFM analysis as a novel framework to discover better customer consumption behavior. *Expert Systems with Applications*, 38(12), 14499–14513.
- Cheng, C.-H., & Chen, Y.-S. (2009). Classifying the segmentation of customer value via RFM model and RS theory. *Expert systems with applications*, 36(3), 4176–4184.
- Christy, A. J., Umamakeswari, A., Priyatharsini, L., & Neyaa, A. (2018). RFM ranking—An effective approach to customer segmentation. *Journal of King Saud University-Computer and Information Sciences*.
- Dogan, O., Ayçin, E., & Bulut, Z. (2018). Customer segmentation by using RFM model and clustering methods: a case study in retail industry. *International Journal of Contemporary Economics and Administrative Sciences*, 8(1), 1–19.
- Dursun, A., & Caber, M. (2016). Using data mining techniques for profiling profitable hotel customers: An application of RFM analysis. *Tourism management perspectives*, 18, 153–160.
- Frederick, N. (1997). *The new rules of marketing: How to use one-to-one relationship marketing to be the leader in your industry*. McGraw-Hills Companies Inc., New York.
- Han, J., Pei, J., & Kamber, M. (2011). *Data mining: concepts and techniques*. Elsevier.
- Hiziroglu, A. (2013). Soft computing applications in customer segmentation: State-of-art review and critique. *Expert Systems with Applications*, 40(16), 6491–6507.
- Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern recognition letters*, 31(8), 651–666.

- Jenkinson, A. (1994). Beyond segmentation. *Journal of targeting, measurement and analysis for marketing*, 3(1), 60–72.
- Kabasakal, İ. (2020). Customer segmentation based on recency frequency monetary model: A case study in E-retailing. *Bilişim Teknolojileri Dergisi*, 13(1), 47–56.
- Karaboğa, K. (2020). Big Data and Data Mining. İçinde G. Mert, E. Şen, & O. Yılmaz (Ed.), *Data, Information and Knowledge Management* (ss. 21–44). Nobel Bilimsel Eserler.
- Khalili-Damghani, K., Abdi, F., & Abolmakarem, S. (2018). Hybrid soft computing approach based on clustering, rule mining, and decision tree analysis for customer segmentation problem: Real case of customer-centric industries. *Applied Soft Computing*, 73, 816–828.
- Kotler, P. (1967). *Marketing management: Analysis planning, and control*. Prentice-Hall, Incorporated.
- Kotler, P. (2003). *Marketing Management*. Prentice Hall.
- Mishra, B. K., Hazra, D., Tarannum, K., & Kumar, M. (2016). Business intelligence using data mining techniques and business analytics. 2016 International Conference System Modeling & Advancement in Research Trends (SMART), 84–89.
- Monalisa, S., Nadya, P., & Novita, R. (2019). Analysis for Customer Lifetime Value Categorization with RFM Model. *Procedia Computer Science*, 161, 834–840.
- Moradpour, S., & Long, S. (2019). Using combined multi-criteria decision-making and data mining methods for work zone safety: a case analysis. *Case studies on transport policy*, 7(2), 178–184.
- Rençber, Ö. F. (2019). Veri Madenciliğinde Kullanılan Kümeleme Algoritmalarının Karşılaştırılması Üzerine Bir İnceleme. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 7(3), 1671–1685.
- Serhat, P., Altan, K., & Erhan, E. P. (2017). LRFMP model for customer segmentation in the grocery retail industry: a case study. *Marketing Intelligence & Planning*, 35(4), 544–559. <https://doi.org/10.1108/MIP-11-2016-0210>
- Smith, W. R. (1956). Product differentiation and market segmentation as alternative marketing strategies. *Journal of marketing*, 21(1), 3–8.
- Wang, T., & Zatzick, C. D. (2019). Human capital acquisition and organizational innovation: A temporal perspective. *Academy of Management Journal*, 62(1), 99–116.
- Wei, J.-T., Lee, M.-C., Chen, H.-K., & Wu, H.-H. (2013). Customer relationship management in the hairdressing industry: An application of data mining techniques. *Expert Systems with Applications*, 40(18), 7513–7518.
- Wu, J., & Lin, Z. (2005). Research on customer segmentation model by clustering. *Proceedings of the 7th international conference on Electronic commerce*, 316–318.
- Yeh, I.-C., Yang, K.-J., & Ting, T.-M. (2009). Knowledge discovery on RFM model using Bernoulli sequence. *Expert Systems with Applications*, 36(3), 5866–5871.
- Zabinsky, Z. B. (2011). *Random Search Algorithms*. İçinde Wiley Encyclopedia of Operations Research and Management Science. <https://doi.org/10.1002/9780470400531.eorms0704>
- Zhu, Q., Sarkis, J., & Lai, K.-H. (2017). Regulatory policy awareness and environmental supply chain cooperation in China: A regulatory-exchange-theoretic perspective. *IEEE Transactions on Engineering Management*, 65(1), 46–58.

Research Article**RFM Metriklerini Kullanarak Kümeleme Yöntemi ile Müşteri
Bölümlendirme: Perakende Sektöründe Bir Uygulama***Customer Segmentation with Clustering Method Using RFM Metrics: An Application in
Retail Industry*

İlhami TUNCER Dr. Öğr. Üyesi, Karamanoğlu Mehmetbey Üniversitesi İİBF, Uluslararası Ticaret ve İşletmecilik ituncer@kmu.edu.tr https://orcid.org/0002-6883-4461	Kazım KARABOĞA Dr. Öğr. Üyesi, Necmettin Erbakan Üniversitesi Uygulamalı Bilimler Fakültesi Yönetim Bilişim Sistemleri kkaraboga@erbakan.edu.tr https://orcid.org/0000-0002-4365-1714
--	---

Extensive Summary

Today, the development of computer, internet and database technologies has enabled businesses at all levels to record demographic, economic and behavioral data about their customers and to have large volumes of data. As a result of recording more information about customers in databases, “data mining and therefore customer segmentation” applications are among the most frequently used fields in the retail sector (Han et al., 2011). Because, considering customers and business processes, it can be quite easy to record and process data related to "sales, consumption, transportation, re-delivery" (Anitha and Patil, 2019) and many similar operational processes with statistics, data mining algorithms and computer technologies. The use of data mining algorithms in the retail industry helps to identify and effectively map customer behavior and related patterns throughout the entire lifecycle of business transactions. As a result, data mining methods - customer segmentation analysis, one of the most used methods - allow improving customer service, developing effective sales and distribution strategies, and much more. Based on customer segmentation analysis, statistical results and indicators, businesses in the retail industry can design various sales and marketing strategies such as promotional campaigns, expanding seasonal discounts or cross-selling, enabling coupons to increase sales and increase customer retention (Han et al., 2011).

This study aims to perform customer segmentation by taking into account the past customer purchasing data of a local retail business operating in Karaman province, and accordingly, loyal and profitable customer groups. It is aimed to increase sales and profitability by enabling the customer groups that emerge as a result of this customer segmentation to develop different campaigns and sales promotion efforts. Based on RFM metrics, k-mean clustering analyzes are used to perform customer segmentation. In this study, after explaining the concept of customer segmentation, information is given about cluster analysis with RFM and k-mean method. In addition, customer segmentation analysis results are reported based on real retail data, and possible campaign suggestions are presented for the retail business. The study is expected to contribute to the national literature in terms of realizing customer segmentation with RFM and k-mean methods.

Customers' needs and requests may differ due to various factors. Therefore, this difference is reflected in the purchasing behavior of consumers and may enter different service or product expectations from businesses. Business managers resorted to customer segmentation in order to find a solution to this problem (Serhat et al., 2017). Because customer segmentation combines similar customers to group them or separates one customer with the feature that makes the other different (Hiziroglu, 2013; Jenkinson, 1994). This concept was first introduced by Smith (1956) and has been successfully applied in practice, supported by many scientific studies. Since then, with the increase of online data, customer segmentation has become a scientifically continuous area of research (An et al., 2018; Bonoma and Shapiro, 1984).

A customer focused marketing strategy is important as it helps strengthen relationships between customers and the business. With this strategy, exploring customer characteristics and meeting customer requirements increases customer loyalty and increases profitability by contributing to minimizing the risk in business operations (Cheng and Chen, 2009). It is important to discover customer characteristics and segment customers according to these characteristics in terms of developing customer-oriented policies. Customer segmentation and clustering techniques are widely used to discover the purchasing behavior of different customer groups (Chang and Tsai, 2011; Wu and Lin, 2005; Yeh et al., 2009). RFM analysis is a technique that can measure the contribution of customers and business profitability by creating customer segments (Chang and Tsai, 2011; Wu and Lin, 2005).

Cluster analysis is a data mining method that is frequently used in the literature, has numerous uses and has a large number of published algorithms. One of the methods frequently used in clustering analysis is K-means (K-means) algorithms. K-mean algorithms were first published in 1955. Although K-means were proposed 50 years ago and thousands of clustering algorithms have been published since then, K-means are still widely used. This method is widely used in a wide variety of disciplines such as psychology, biology, and marketing research (Jain, 2010; Moradpour and Long, 2019; Zhu et al., 2017). K-mean cluster analysis is used in the field of marketing research, such as customer grouping and workforce management and planning (Arabie and Hubert, 1994).

In this study, it is aimed to segregate customers operating in the retail sector within the framework of RFM metrics so that businesses can develop various strategies. In this context, the data were obtained from a shopping center operating in the retail sector in the province of Karaman. The data includes information on “purchase frequency”, “last shopping date” and “total basket amount” for 6600 customers. This secondary data covers transactions between January 2019 - November 2020. The form regarding the information to be requested before these data was requested was submitted to the ethics committee, and the data were obtained after the approval of the ethics committee. The analysis of these data consists of two stages. In the first stage, RFM analysis was performed by using the information about the customers' up-to-dateness, frequency and monetary metrics, and thus the RFM score of each customer was reached. Customers are divided into segments within the framework of RFM scores. In the second stage, the scores formed by RFM metrics were accepted as data, and a second segmentation was performed by dividing the customers into clusters with the K-average method within the framework of these values. SPSS 22 and R Programs were used in the analysis of these data.

When we examine the values in Table 4, we can state that the most profitable customers are gathered in cluster 3. Because we can say that the average up-to-datedness value is quite recent, the frequency level is by far higher than the other clusters and the average basket amount is higher than the other clusters. Therefore, it is the most loyal customer group for this business. The 2nd profitable customer for this business is cluster number 2. Although the monetary value is relatively low compared to cluster number 5, the currency and frequency of customers is quite high. However, when we examine the number of segmentation customers according to the RFM scores in Table 3, the number of potential loyal customers is important and the business loyalty to these customers will increase the average monetary value of the customers in cluster 2. On the

other hand, according to the values in Table 3, the weakest link among the 6 clusters is the customer group that constitutes the cluster number 1. When compared with other sets, it is understood that the value of each variable is lower than the others. Therefore, it constitutes the most unprofitable customer group for the business.

This study makes some contributions to the literature. When we examine the literature, we can say that according to our knowledge, scientific studies on customer segmentation focus more on segmentation analysis methods and fewer studies have been revealed from a marketing perspective. Therefore, this study will contribute to the enrichment of the literature due to its evaluation from a marketing perspective. In addition, in this study, a cluster was performed within the framework of RFM scores in the first stage, and then a cluster analysis was performed with k-mean. In the analysis made with K-environment, a different perspective is presented by giving detailed information about the cluster types made with RFM. We can say that this is the first according to our literature review. This detail can provide important clues in creating marketing strategies. Moreover, when we examine the national literature, it is seen that such studies are limited. Therefore, it will be able to contribute to the enrichment of the national literature.