

MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE MÜŞTERİ KAYBI ANALİZİ

Oğuz KAYNAR¹

Murat Fatih TUNA²

Yasin GÖRMEZ³

Mehmet Ali DEVECİ⁴

Özet

Müşteri davranışlarını inceleyerek ayrılması muhtemel müşterilere ait profilleri çıkarıp terk etme olasılığı yüksek müşterileri önceden tahmin etme işlemi müşteri kaybı analizi olarak adlandırılmaktadır. Yeni müşteri kazanma maliyetinin eldeki müşteriyi tutma maliyetinden daha yüksek olması, müşteri terk etme analizini stratejik karar verme ve planlama sürecinin vazgeçilmez bir parçası haline getirmiştir. Hızla büyüyen ve rekabet ortamının her geçen gün arttığı, müşterilerin kolaylıkla operatör değiştirdiği ve bu nedenle firmaların milyonlarca dolar zarar ettiği telekomünikasyon sektöründe, müşteri ayrılma analizi daha da önem kazanmaktadır. Müşteri kaybı analizi, rakip firmaya geçmeyi planlayan müşterileri önceden tahmin ederek, şirkete bu müşterilerin bağlılığını arttırmayı hedefleyen çeşitli kampanyalar ve politikalar geliştirme fırsatı sunar. Müşteri kaybı analizi için son yıllarda veri madenciliği ve yapay zekâ teknikleri sıkça kullanılmaya başlanmıştır. Bu çalışmada, telekomünikasyon sektöründe müşteri kaybını tahmin etmek için, Destek Vektör Makineleri (DVM), Yapay Sinir Ağları (YSA) ve Naive Bayes (NB) gibi çeşitli sınıflama yöntemleri yardımıyla bir analiz gerçekleştirilmiştir. Analiz, açık erişimli bir veri tabanından elde edilen, 4667 müşteriden oluşan ve her müşteri için 21 adet işlem kaydına ait özellikler ile müşterinin terk edip terk etmediğine dair sınıf bilgisi içeren bir veri seti üzerinde gerçekleştirilmiştir. Analiz sonucunda, sadık ya da terk eden müşterileri sınıflamada yapay sinir ağları, diğer makine öğrenmesi yöntemlerine göre daha başarılı olmuştur.

Anahtar Kelimeler: Müşteri Kaybı, Makine Öğrenmesi, Destek Vektör Makineleri, Yapay Sinir Ağları, Naive Bayes

Customer Churn Analysis Via Machine Learning Methods

Abstract

As it is widely known in marketing, it is more costly to gain a new customer than retain an already existing loyal customer. Indeed, this conviction highlights the importance of precluding of customer churn. To enhance a slightly different approach to customer churn management, data set derived from a real-world telecommunication firm has been analyzed. The data set which contains 4667 rows and 21 features has been derived from a

¹ Doç. Dr., Cumhuriyet Üniversitesi, İİBF, YBS Bölümü, okaynar@cumhuriyet.edu.tr

² Arş. Gör., Cumhuriyet Üniversitesi, İİBF, YBS Bölümü, mftuna@cumhuriyet.edu.tr

³ Arş. Gör., Cumhuriyet Üniversitesi, İİBF, YBS Bölümü, yasingormez@cumhuriyet.edu.tr

⁴ Arş. Gör., Cumhuriyet Üniversitesi, İİBF, YBS Bölümü, madeveci@cumhuriyet.edu.tr

publicly open-access database and reflects transactions of the firm. Support Vector Machines (SVM), Artificial Neural Network (ANN) and Naive Bayes (NB) algorithms have been used as analyzing methods and performance of the analysis has been evaluated via four accuracy measures. In consequence of analysis, the ANN method had the perfect mean result and reflected the best accuracy performance. It is thought that this study guides further studies which use machine learning methods to predict customer churn.

Key Word: Customer Churn, Machine Learning, Support Vector Machines, Artificial Neural Network, Naive Bayes

GİRİŞ

Günümüzde artan rekabet ortamı, pazarlamada odak noktası olarak kabul edilen, müşteriye ve onun bir tüketici olarak davranışlarını son derece detaylı bir biçimde izlemeyi (M. Accardi-Petersen, 2011, s. 98), böylelikle bir tüketici olarak da satın alma karar süreçlerini ve davranışlarını dikkatle takip etmeyi zorunlu kılmaktadır (Linoff & Berry, 2004, p. 3). Bu noktada günümüzün tüketim alışkanlıkları göz önünde bulundurulduğunda ve firmaların hayatta kalmalarının müşteriye bu derece bağlı olduğu bir durumda, aslında müşterinin mübadelede kuralları belirleyen taraf olduğunu söylemek mümkündür. Bu sebeple günümüz ekonomi ortamını “müşterinin kral olduğu bir müşteri ekonomisi” olarak tanımlamak mantıklı olacaktır (Kotler, 2003, s. 36).

Böyle bir ekonomi ortamında müşteriler bir örgütün varlık nedenlerindedir ve uzun vadeli yüksek müşteri tatmininin sağlanması, ancak ve ancak etkili bir müşteri ilişkileri yönetimi süreci yaratmakla mümkündür (Tsiptsis ve Chorianopoulos, 2009, s. 1). Nitekim müşteri ile karşılıklı fayda ilkesine dayanan uzun vadeli bir ilişki kurma anlamına gelen Müşteri İlişkileri Yönetimi (MİY), aynı zamanda kârlı olan müşterilerle daha az kârlı müşteriler arasında bir seçim yapma süreci niteliği taşımaktadır. MİY'in temel hedefleri şu şekilde özetlenebilir (Bagheri ve Tarokh, 2015; Farquad, Ravi ve Raju, 2014; Helfert ve Heinrich, 2003):

- Müşterilere ilişkin verilerin toplanması
- Müşterilere ilişkin verilerin ilgili birimlere sunulması
- Müşterilerin satın alma alışkanlıklarına bakılarak değerlerinin keşfedilmesi
- Müşterilerin değerlerine göre sınıflandırılması
- Müşteriyle çok kanallı iletişimin sağlanması
- Müşterilerin sadakatini arttıracak operasyonların gerçekleştirilmesi
- Çeşitli ürünlerin çapraz satış ve üst satışlarının gerçekleştirilmesi

MİY kavramının teknoloji ve yönetim şeklindeki iki yönlü yapısı kavramın stratejik (müşteri merkezli bir iş kültürü oluşturma gibi), operasyonel (çeşitli müşteri bilgilerini elde etme gibi) ve analitik (elde edilen verilerin analiz edilmesi gibi) perspektiflerden ele alınmasını gerektirmektedir (Buttle ve Maklan, 2015).

Tüm bu süreçleri ele alacak bir MİY yapısının aynı zamanda bazı temellere odaklanması gerekmektedir. Bu anlamda etkili bir müşteri ilişkileri yönetim süreci aşağıdaki dört temel başlık çerçevesinde incelenebilmektedir (Kumar & Petersen, 2012):

- Müşteri kazanımı
- Müşterilerin elde tutulması
- Müşteri kaybı
- Müşterinin geri kazanımı

I. MÜŞTERİ KAYBI

Bu dört ana unsurdan müşteri kaybı, en basit tanımıyla “*rekabet nedeniyle müşterilerin firmayı tercih etmekten vazgeçmeleri*” anlamına gelmektedir (Nettleton, 2014, s. 19). Hem firma hem de müşteri düzeyinde popüler MİY ölçeklerinden birisi olan müşteri kaybı (Kumar ve Petersen, 2012, s. 8); müşterinin *t-1* periyodunda son alışverişini yapmasına karşın *t* periyodunda odağını firmanın dışına kaydırmasını ifade etmektedir. Nitekim firmalar artan rekabet ortamında bir takım kararlar alırken öncelikli olarak sadık müşterilerinden gelecek istikrarlı gelire odaklanacaklardır ki (Sharma ve Panigrahi, 2011) bu durum mevcut müşterilerin elde tutulmasını daha da zorunlu hale getirecektir. Bu noktada pazarlamada yaygın olarak bilindiği üzere, eldeki bir müşteriye firmada tutmak, yepyeni bir müşteriye sadık hale getirmekten çok daha maliyetli olmaktadır. Nitekim müşteri kaybı yönetimi adı verilen süreçte başarılmak istenen, firmayı tercih etmeyi bırakma ihtimali olan müşterilerin oranını yönetmektir (Kumar ve Petersen, 2012, s. 3). İşte bu yüzden müşteri kaybının doğru şekilde yönetilmesi, ancak ve ancak firmadan vazgeçme potansiyeli bulunan müşterinin doğru şekilde belirlenmesi ile mümkün olacaktır (K. Kim, Jun ve Lee, 2014). Bu noktada temel amaç, müşterileri kaçacak ve kaçmayacak müşteri şeklinde sınıflandırmaktır.

Müşteri kaybı kavramı, banka ve telekomünikasyon firmaları gibi hizmet işletmelerinin, müşterilerinin sadakatlerindeki değişimlerin ve bu değişimlerin sonucunda müşterinin firmayı tercihten vazgeçmelerinin artmasıyla daha fazla gündeme gelmiştir. Müşteri kaybının yüksek olmasında, firmaların birbirinden çok farklı özelliklerde ve çok çeşitli kampanyalar oluşturarak rakip firmada tatminsizlik yaşayan müşteriye cezbetme potansiyelinin yüksek olması çok etkilidir. Müşteriler son teknolojilere erişme imkânı, müşteri dostu çalışan kadrosu, düşük işlem ücretleri, değişim maliyeti, reklâm etkisi, coğrafi yakınlık ve çeşitli hizmet tekliflerinden ötürü diğer firmalara geçiş eğilimi göstermiştir (Farquad et al., 2014; Hejazinia ve Kazemi, 2014). Bu eğilimi önceden tahmin edebilmek işletmeye hem firmanın elinden kaçırması muhtemel müşterileri erken tespit ederek onlar üzerine kampanyalar düzenleme imkânı verecek, hem de firmadan kaçmış olan müşterileri tekrar işletmeye kazandırırken hangi noktaların dikkate alınacağına dair bir ön bilgi sağlayacaktır. Aslında bu durum müşteriye firmadan soğutan temel aksaklığın

kaynağına bir müdahale imkânı tanıyacak olmasından ötürü, uzun vadede firma faaliyetleri üzerinde iyileştirici ve geliştirici bir etki de yaratacaktır. Bu durum, firmanın hem sadık müşterilerinin sadakatlerinin devamlılığını sağlama, hem de sadık olmayan müşteriyi sadık hale getirme noktasında kilit bir etkiye sahip olacaktır. Nitekim sadık müşterilerin rakip firmaların tekliflerine çoğunlukla kendilerini kapatarak, sadık kaldıkları firmaya düzenli bir gelir getirme potansiyellerinin bulunduğu yaygın olarak bilinmektedir (Hosseini, Maleki ve Gholamian, 2010). Bu durum da müşteri kaybının tahminine ilişkin modellerin geliştirilmesini zorunlu kılmıştır.

Müşteri kaybını tahmin etmeye yönelik modellerin amacı firmadan kopma ihtimali yüksek olan müşteriyi önceden saptamaktır (Verbeke, Martens ve Baesens, 2014). Literatür incelendiğinde, müşteri kaybını hedef alan çalışmaların başta **telekomünikasyon ve iletişim sektörü** [(Coussement, Lessmann ve Verstraeten, 2016; Geetha ve Abitha Kumari, 2012; Hejazinia ve Kazemi, 2014; B. Huang, Kechadi ve Buckley, 2012; Y. Huang ve Kechadi, 2013; N. Kim, Jung, Kim ve Lee, 2012; Kirui, Hong, Cheruiyot ve Kirui, 2013; Kisioglu ve Topcu, 2011; Wei ve Chiu, 2002)], **bankacılık sektörü** [(Ahn et al., 2006; J. Burez ve Van den Poel, 2009; De Bock ve Van den Poel, 2012; Gür Ali ve Arıtürk, 2014; Xie ve Li, 2008)], **perakendecilik sektörü** [(Gordini ve Veglio, 2016; Miguéis, Van den Poel, Camanho ve Falcão e Cunha, 2012; Tamaddoni Jahromi, Stakhovych ve Ewing, 2014), **sigortacılık sektörü** [(Günther, Tvette, Aas, Sandnes ve Borgan, 2014; Holtrop, Wieringa, Gijzenberg ve Verhoef, n.d.)], **enerji sektörü** [(Moeyersoms ve Martens, 2015)] ile **oyun ve eğlence sektörü** [(Coussement ve De Bock, 2013; Kawale, Pal ve Srivastava, 2009)], hatta ücretli online arkadaşlık siteleri [(S.-H. Chen, 2016)] olmak üzere müşteri ilişkilerinin yönetildiği birçok alanda uygulanabildiği görülmektedir.

Literatür incelemesi yapıldığında müşteri kaybını tahmin etmeye yönelik farklı yöntemlerin izlendiği görülmüş, müşteri kaybının tahmin edilmesi amacıyla literatürdeki çalışmaların bir takım makine öğrenmesi algoritmaları üzerinde yoğunlaştıkları tespit edilmiştir. Bu metotların arasında **Destek Vektör Makinaları** [(Z.-Y. Chen, Fan ve Sun, 2012; Farquad et al., 2014; Gordini ve Veglio, 2016; Moeyersoms ve Martens, 2015)], **Lojistik Regresyon** [(Ahn et al., 2006; Dierkes, Bichler ve Krishnan, 2011; Haenlein, 2013; Abbas Keramati ve Ardabili, 2011)], **Karar Ağaçları** [(Gür Ali ve Arıtürk, 2014; Nie et al., 2011; Tamaddoni Jahromi et al., 2014)], **Yapay Sinir Ağları** [(W.-C. Lin, Tsai ve Ke, 2014; Tsai ve Lu, 2009; Xie ve Li, 2008; Zhao, Li, Li, Liu ve Ren, 2005)], **K-En Yakın Komşuluk** [(Fathian, Hoseinpoor ve Minaei-Bidgoli, 2016; Idris et al., 2012; A. Keramati et al., 2014)], **Naive Bayes** [(B. Huang et al., 2012; Saradhi ve Palshikar, 2011; Vafeiadis, Diamantaras, Sarigiannidis ve Chatzisavvas, 2015)], **Random Forest** [(Jonathan Burez ve Van den Poel, 2007; Coussement ve De Bock, 2013; De Bock ve Poel, 2011)] bulunmaktadır.

Müşteri kaybına ilişkin geliştirilen modellerde, müşterilerin önceki alışverişlerinden elde edilen bilgiler her müşteri için tek tek analiz edilerek tahmin yapılmaktadır. Artan müşteri sayısı göz önüne alındığında, bu analizlerin insan eliyle yapılması neredeyse imkânsız bir hal almıştır. Bu nedenle firmalar günümüzde sıkça kullanılan veri madenciliği yöntemlerini müşteri kaybı verilerine uygulamayı tercih etmişlerdir. Bu çalışmada veri madenciliği yöntemlerinden Destek Vektör Makinaları (DVM), Naive Bayes (NB) ve Çok Katmanlı Yapay Sinir Ağları (YSA) kullanılarak müşteri kaybına ilişkin tahmin yapan 3 farklı model geliştirilmiştir.

II. YÖNTEMLER

A.YAPAY SİNİR AĞLARI

Yapay Sinir Ağları (YSA) insan sinir sistemini taklit ederek öğrenmeyi hedefleyen denetimli bir makine öğrenmesi yöntemidir. Yapay sinir ağı modeli, bir katmanda bulunan nöronların takip eden katmandaki nöronlara bağlanması ile oluşturulur. En sık kullanılan yapay sinir ağı modeli olan çok katmanlı algılayıcı sinir ağı (MLP) modeli; girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç farklı katmandan meydana gelmektedir. Girdi katmanı verilerin okunduğu katmandır. Her bir nöron bir özelliği temsil ettiği için özellik sayısı kadar nöron içermektedir. Çıktı katmanı ise sınıfların belirlendiği katmandır. Bu katman oluşturulan modele göre tek bir nöron içerebileceği gibi sınıf çeşidi sayısı kadar nöron da içerebilmektedir. Gizli katman ise girdi katmanı ile çıktı katmanı arasında yer alan verilerin ara işleme maruz kaldığı katmandır. Gizli katman sayısı ve bir gizli katmandaki nöron sayısı tam olarak belirli olmamakla birlikte eğitimin kalitesini etkileyen önemli iki faktördür. MLP modelinde öğrenme bir önceki katmandan takip eden katmana doğru yapıldığı için ileri beslemeli YSA olarak da bilinir. Kullanılan eğitim algoritması hatanın karesini en aza indirecek şekilde ağırlıkları güncellemeyi hedefler.

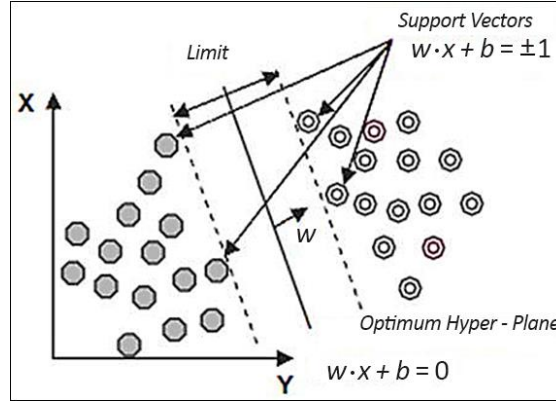
$$y_i = f\left(\sum_{j=1}^n x_j * w_{ji}\right) \quad (1)$$

$$E(w) = \frac{1}{2} \sum_{k \in \text{outputs}} (t_k - o_k)^2 \quad (2)$$

Eşitlik (1) MLP modelinde ileri beslemeyi, eşitlik (2) ise geri beslemeyi formüle etmektedir. Eşitlik 1’de x_j ; mevcut katmandaki j. nöronun değerini, y_i ; takip eden katmandaki i’inci nörona aktarılan değeri, n; mevcut katmandaki nöron sayısını, w_{ji} ; mevcut katmandaki j. nörondan takip eden katmandaki i. nörona giden ağırlığı, f ise aktivasyon fonksiyonunu (gauss, softmax, sigmoid vb.) temsil etmektedir. Eşitlik 2’de k; veri setindeki örnek sayısını, t_k ; verilerin gerçek sınıfını, o_k ise modelin ürettiği sınıf değerini temsil etmektedir.

B. DESTEK VEKTÖR MAKİNALARI

Destek vektör makinesi iki boyutlu uzayda doğrusal, üç boyutlu uzayda düzlemsel ve çok boyutlu uzayda hiperdüzlem şeklindeki ayırma mekanizmaları ile veriyi iki ya da daha çok sınıfa ayırma yeteneğine sahiptir. Lineer olarak ayrıştırılabilen sınıfların belirlenmesinde sıkça kullanılan yöntem, kernel fonksiyonları sayesinde doğrusal olarak ayrıştırılamayan girdi uzayını daha yüksek boyutlu lineer olarak ayrıştırılabilen bu uzaya taşıyarak, doğrusal olmayan verilerin sınıflandırılmasında başarıyla kullanılmaktadır. Eğitim için kullanılacak N elemandan oluşan verinin $Q = \{x_i, y_i\}$, $i = 1, 2, \dots, N$ olduğu varsayılırsa x_i ; öznitelik vektörünü, y_i ise sınıf değerlerini gösterir. Lineer olarak ayrılma durumunda, bu iki değerli veriler direkt olarak bir ayırıcı düzlem ile ayrılabilir. Veri setini sınıflara ayırabilecek sonsuz sayıda çoklu düzlem çizilebilmesine karşın amaç, bilinmeyen sınıflama hatasını en küçük yapacak hiperdüzlemi seçmektir. Şekil 2’de görüleceği üzere $f(\vec{x}) = \vec{w}^T \vec{x} + b \geq 1$ durumu birinci sınıfı, ($y_i = 1$) ve $f(\vec{x}) = \vec{w}^T \vec{x} + b \leq -1$ durumu ise ikinci sınıfı ($y_i = -1$) temsil eder.



Şekil 1. Destek Vektör Makineleri ve Hiperdüzlem Seçimi

İki sınır arasındaki uzaklık $\lambda = 2/\vec{w}^2$ formülü ile ifade edilir. Amaç, λ değerini maksimum yapmak olduğu için $1/\lambda$ ifadesi minimum olmalıdır. Buna bağlı sınırlama ise $y_i(\vec{w}^T \vec{x}_i + b) - 1 \geq 0$, $y_i \in \{-1, +1\}$ 'dir. İlgili problemin duali, Eşitlik 3'te verilmiştir. Eşitlikteki problem, Lagrange denklemleri, Eşitlik 4 ve Eşitlik 5'te verilen "Karush-Kuhn-Tucker (KKT)" in kısıtları yardımıyla çözülür.

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^N \alpha_i [y_i(\mathbf{w}^T \mathbf{x}_i + w_0) - 1] \quad \alpha_i \geq 0, \forall i \quad (3)$$

$$\frac{\partial L}{\partial w_j} = 0, \forall j \quad (4)$$

$$\frac{\partial L}{\partial w_0} = 0 \quad (5)$$

Kernel fonksiyonu kullanılarak doğrusal olmayan dönüşümler yapılabilen ve yüksek boyutta doğrusal ayırım gerçekleştirilebilmektedir. En yaygın kernel fonksiyonları Gauss, Polinomial ve Sigmoid fonksiyonlarıdır.

C. NAIVE BAYES

Naive Bayes, Bayes teoreminden faydalanılarak oluşturulmuş sınırlandırma için kullanılan anlaşılabilir ve kolaylıkla uygulanabilir en basit makine öğrenme algoritmalarından biridir. Bu yöntemle bir örneğin hedef niteliğinin sınıf değerine ait olma olasılığı bulunabilmektedir. Bayes teoremi:

$$P(H|X) = \frac{P(X|H)P(H)}{P(X)} \quad (6)$$

Eşitlikte X; öznitelik vektörü, H ise bir öznitelik vektörünün C gibi bir sınıfa ait olma olasılığını ifade eden hipotezdir. P(H|X) ise ardıl olasılığı temsil eder. Bayes teoremi göz önüne alındığında Naive Bayes sınıflandırıcısının algoritması ise şu şekildedir;

D'nin veri setini temsil ettiği ve D'deki her X'in sınıf etiketinin belirli olduğu varsayalım. X, n tane öznitelikten oluşan bir vektördür ve $X=(x_1, x_2, \dots, x_n)$ olarak temsil edilmektedir. C_1, C_2, \dots, C_m ile temsil edilen m tane sınıf olduğu varsayalım. Naive Bayes sınıflandırıcısı bir X vektörünün C_i sınıfına ait olup olmadığını bulmak için, bütün sınıflar içinde en yüksek $P(C_i|X)$ ardıl olasılığına sahip değeri bulmaya çalışır. Bu durum Bayes teoremi ile eşitlik 7'de ifade edilmiştir.

$$P(C_i|X) = \frac{P(X|C_i)P(C_i)}{P(X)} \quad (7)$$

P(X) değeri tüm sınıflar için aynı olduğundan, yalnızca $P(X|C_i)P(C_i)$ ifadesi maksimum yapılmalıdır. $P(C_i)$ ifadesi, C_i sınıfındaki eleman sayısının, tüm eleman sayısına oranıdır. $P(X|C_i)$ ifadesi ise, X'in n tane değer içeren bir öznitelik vektörü olduğu varsayıldığında aşağıdaki eşitlik ile hesaplanır.

$$P(H|C_i) = \prod_{k=1}^n P(X_k|C_i) \quad (8)$$

Sonuçta, sınıflandırıcı en büyük $P(X|C_i)P(C_i)$ ifadesine sahip olan C_i sınıfını, X vektörünün sınıfı olarak seçer.

III. UYGULAMA

Çalışmada, çağrı merkezi müşteri işlem kayıtlarından elde edilen, 21 öznitelik ile firma ürünlerini kullanmaktan vazgeçen veya firma ürünlerini

kullanmaya devam eden olmak üzere 2 adet farklı sınıf bilgisi içeren veri seti kullanılmıştır. Eğitim için veri setinin 75%'lik kısmı olan 3500 adet, test için ise veri setinin 25%'lik kısmı olan 1167 adet veri rastgele seçilmiştir. Modeller karşılaştırılırken veri setinden doğacak üstünlüklerin engellenmesi için bölme işlemi bir kez yapılmış ve her model için aynı eğitim ve test verileri kullanılmıştır. Oluşturulan bu veri setleri ile DVM, YSA ve NB algoritmaları kullanılarak 3 farklı model tasarlanmıştır. Tablo 1'de her bir model için elde edilen karmaşıklık matris değerleri gösterilmiştir. Bu tabloda P, firmayı tercih etmekten vazgeçen müşteri sayısını; N, firmayı tercih etmeye devam eden müşteri sayısını; eğitim bloğu, modeli eğitmek için kullanılan veri sayılarını; test bloğu, modeli test etmek için kullanılan veri sayılarını; gözlenen bloğu, verilerin gerçek etiketlerini; tahmin bloğu ise verilerin model tarafından tahmin edilen etiketlerini temsil etmektedir. Aynı tabloda N sütunu ile N satırının kesiştiği bölgedeki sayılar TN değerlerini, N sütunu ile P satırının kesiştiği bölgedeki sayılar FP değerlerini, P sütunu ile P satırının kesiştiği bölgedeki sayılar TP değerlerini, P sütunu ile N satırının kesiştiği bölgedeki sayılar ise FN değerlerini ilgili model için göstermektedir.

Tablo 1. Sınıflama sonucunda elde edilen karmaşıklık matrisleri

		Eğitim		Test		
		<i>Gözlenen</i>		<i>Gözlenen</i>		
Naive Bayes	<i>Tahmin</i>		N	P	N	P
		<i>N</i>	1651	181	550	54
		<i>P</i>	276	1392	96	467
DVM	<i>Tahmin</i>		N	P	N	P
		<i>N</i>	1348	190	446	58
		<i>P</i>	579	1383	200	463
YSA	<i>Tahmin</i>		N	P	N	P
		<i>N</i>	1840	138	602	57
		<i>P</i>	87	1435	44	464

Tablo 2'de ise her bir model için tablo 1'de test verisini ilgilendiren sayılar kullanılarak hesaplanan başarı oranı(A), hassasiyet(S), duyarlılık(P) ve F ölçütü(F) değerleri gösterilmiştir. Bu tabloda her bir model için A, $\frac{TP+TN}{TP+TN+FP+FN}$ formülü; S, $\frac{TP}{TP+FN}$ formülü; P, $\frac{TP}{TP+FP}$ formülü; F ise $\frac{2 \times TP}{2 \times TP+FP+FN}$ formülü kullanılarak hesaplanmıştır.

Tablo 2. Test Verisi Sonuç Değerleri

Sınıflayıcı	A	S	P	F-ölçütü
NB	0,8715	0,8964	0,8295	0,8616
DVM	0,7789	0,8887	0,6983	0,7821
YSA	0,9135	0,8906	0,9134	0,9018

Üç model arasından ilgili ölçüt biriminde en yüksek değere sahip model en iyi model olarak değerlendirilmiştir ve her bir ölçüt birimi için bu değerlendirme yapılmıştır. Tablo 2'deki sonuçlardan da görüldüğü üzere A, P ve F ölçüt birimlerinde YSA, S ölçüt biriminde ise NB en iyi sonuçları veren modeller olmuşlardır. DVM kullanılarak tasarlanan modelde ise tüm ölçüt birimlerinde diğerlerine nazaran daha düşük değerli sonuçlar elde edilmiştir.

SONUÇ

Gelişmekte olan ülkelerde müşteri kayıp yönetimi çalışmalarına giderek daha fazla ağırlık verilmektedir. Müşteri kaybı yönetimi üzerine yapılan çalışmaların başında telekomünikasyon sektörünü temel alan çalışmalar gelmektedir. Bu büyük ve rekabetçi pazarda ayakta kalabilmek adına, telekomünikasyon firmalarının muhtemel müşteri kayıplarını doğru tahmin ederek hem sadık müşterilerin işletme içindeki değerlerini korumayı, hem de firmayı tercih etmeyi bırakma eğiliminde olan müşteriyi tekrardan kazandırmayı amaçlayan kampanyaların düzenlenmesi son derece önemlidir. Bu çalışmada çağrı merkezi müşteri işlem kayıtlarından elde edilen 4667 adet veri üzerinde müşteri kaybı analizi yapılmıştır. Müşteri kaybı analizi NB, DVM ve YSA kullanılmak üzere üç farklı model ile yapıp, bu modellerin performansları dört farklı ölçüt yardımı ile kıyaslanmıştır. Sonuçlar incelendiğinde başarı oranı, duyarlılık ve F ölçütü değerlerinde en iyi skorlar sırası ile %91,35, % 91,34 ve % 90,18 olup YSA kullanan model ile elde edilirken, hassasiyet değerinde en iyi skor % 89,64 olup NB kullanan model ile elde edilmiştir. NB ve YSA kullanılarak oluşturulan modellerde beklenene yakın sonuçlar elde edilmiştir. Ancak DVM kullanılarak oluşturulan modelde beklenenden daha düşük performans değerleri elde edilmiştir. Bu durumun veri setindeki bazı özniteliklerden kaynaklandığı düşünülmüştür. Bir sonraki çalışmada öznitelik sayısı ve örnek sayısı daha fazla olan farklı veri setleri ve veri madenciliği yöntemlerinden öznitelik seçim yöntemleri de kullanılarak modeller geliştirilecek ve bu yöntemlerin performans ölçütleri üzerindeki etkileri analiz edilecektir.

KAYNAKÇA

- Ahn, J.-H., Han, S.-P., & Lee, Y.-S. (2006). Customer churn analysis: Churn determinants and mediation effects of partial defection in the Korean mobile telecommunications service industry. *Telecommunications Policy*, 30(10–11), 552–568. <https://doi.org/10.1016/j.telpol.2006.09.006>
- Bagheri, F., & Tarokh, M. J. (2015). Customer behavior mining based on RFM model to improve the customer relationship management. *Journal of Industrial Engineering and Management Studies*, 1(1), 43–57.
- Burez, J., & Van den Poel, D. (2009). Handling class imbalance in customer churn prediction. *Expert Systems with Applications*, 36(3, Part 1), 4626–4636. <https://doi.org/10.1016/j.eswa.2008.05.027>
- Burez, Jonathan, & Van den Poel, D. (2007). CRM at a pay-TV company: Using analytical models to reduce customer attrition by targeted marketing for subscription services. *Expert Systems with Applications*, 32(2), 277–288. <https://doi.org/10.1016/j.eswa.2005.11.037>
- Buttle, F., & Maklan, S. (2015). *Customer Relationship Management: Concepts and Technologies* (3 edition). London ; New York: Routledge.
- Chen, S.-H. (2016). The gamma CUSUM chart method for online customer churn prediction. *Electronic Commerce Research and Applications*, 17, 99–111. <https://doi.org/10.1016/j.elerap.2016.04.003>
- Chen, Z.-Y., Fan, Z.-P., & Sun, M. (2012). A hierarchical multiple kernel support vector machine for customer churn prediction using longitudinal behavioral data. *European Journal of Operational Research*, 223(2), 461–472. <https://doi.org/10.1016/j.ejor.2012.06.040>
- Coussement, K., & De Bock, K. W. (2013). Customer churn prediction in the online gambling industry: The beneficial effect of ensemble learning. *Journal of Business Research*, 66(9), 1629–1636. <https://doi.org/10.1016/j.jbusres.2012.12.008>
- Coussement, K., Lessmann, S., & Verstraeten, G. (2016). A comparative analysis of data preparation algorithms for customer churn prediction: A case study in the telecommunication industry. *Decision Support Systems*. <https://doi.org/10.1016/j.dss.2016.11.007>
- De Bock, K. W., & Poel, D. V. den. (2011). An empirical evaluation of rotation-based ensemble classifiers for customer churn prediction. *Expert Systems with Applications*, 38(10), 12293–12301. <https://doi.org/10.1016/j.eswa.2011.04.007>
- De Bock, K. W., & Van den Poel, D. (2012). Reconciling performance and interpretability in customer churn prediction using ensemble learning based

- on generalized additive models. *Expert Systems with Applications*, 39(8), 6816–6826. <https://doi.org/10.1016/j.eswa.2012.01.014>
- Dierkes, T., Bichler, M., & Krishnan, R. (2011). Estimating the effect of word of mouth on churn and cross-buying in the mobile phone market with Markov logic networks. *Decision Support Systems*, 51(3), 361–371. <https://doi.org/10.1016/j.dss.2011.01.002>
- Farquad, M. A. H., Ravi, V., & Raju, S. B. (2014). Churn prediction using comprehensible support vector machine: An analytical CRM application. *Applied Soft Computing*, 19, 31–40. <https://doi.org/10.1016/j.asoc.2014.01.031>
- Fathian, M., Hoseinpoor, Y., & Minaei-Bidgoli, B. (2016). Offering a hybrid approach of data mining to predict the customer churn based on bagging and boosting methods. *Kybernetes*, 45(5), 732–743. <https://doi.org/10.1108/K-07-2015-0172>
- Geetha, M., & Abitha Kumari, J. (2012). Analysis of churn behavior of consumers in Indian telecom sector. *Journal of Indian Business Research*, 4(1), 24–35. <https://doi.org/10.1108/17554191211206780>
- Gordini, N., & Veglio, V. (2016). Customers churn prediction and marketing retention strategies. An application of support vector machines based on the AUC parameter-selection technique in B2B e-commerce industry. *Industrial Marketing Management*. <https://doi.org/10.1016/j.indmarman.2016.08.003>
- Günther, C.-C., Tvette, I. F., Aas, K., Sandnes, G. I., & Borgan, Ø. (2014). Modelling and predicting customer churn from an insurance company. *Scandinavian Actuarial Journal*, 2014(1), 58–71. <https://doi.org/10.1080/03461238.2011.636502>
- Gür Ali, Ö., & Arıtürk, U. (2014). Dynamic churn prediction framework with more effective use of rare event data: The case of private banking. *Expert Systems with Applications*, 41(17), 7889–7903. <https://doi.org/10.1016/j.eswa.2014.06.018>
- Haenlein, M. (2013). Social interactions in customer churn decisions: The impact of relationship directionality. *International Journal of Research in Marketing*, 30(3), 236–248. <https://doi.org/10.1016/j.ijresmar.2013.03.003>
- Hejazinia, R., & Kazemi, M. (2014). Prioritizing factors influencing customer churn, 5(12).
- Helfert, M., & Heinrich, B. (2003). Analyzing Data Quality Investments in CRM: A Model-Based Approach (pp. 80–95). Presented at the Proceedings of the Eighth International Conference on Information Quality, Massachusetts:

ACM Digital Library. Retrieved from <https://epub.uni-regensburg.de/23811/1/heinrich.pdf>

- Holtrop, N., Wieringa, J. E., Gijzenberg, M. J., & Verhoef, P. C. (n.d.). No future without the past? Predicting churn in the face of customer privacy. *International Journal of Research in Marketing*. <https://doi.org/10.1016/j.ijresmar.2016.06.001>
- Hosseini, S. M. S., Maleki, A., & Gholamian, M. R. (2010). Cluster analysis using data mining approach to develop CRM methodology to assess the customer loyalty. *Expert Systems with Applications*, 37(7), 5259–5264. <https://doi.org/10.1016/j.eswa.2009.12.070>
- Huang, B., Buckley, B., & Kechadi, T.-M. (2010). Multi-objective feature selection by using NSGA-II for customer churn prediction in telecommunications. *Expert Systems with Applications*, 37(5), 3638–3646. <https://doi.org/10.1016/j.eswa.2009.10.027>
- Huang, B., Kechadi, M. T., & Buckley, B. (2012). Customer churn prediction in telecommunications. *Expert Systems with Applications*, 39(1), 1414–1425. <https://doi.org/10.1016/j.eswa.2011.08.024>
- Huang, Y., & Kechadi, T. (2013). An effective hybrid learning system for telecommunication churn prediction. *Expert Systems with Applications*, 40(14), 5635–5647. <https://doi.org/10.1016/j.eswa.2013.04.020>
- Idris, A., Rizwan, M., & Khan, A. (2012). Churn prediction in telecom using Random Forest and PSO based data balancing in combination with various feature selection strategies. *Computers & Electrical Engineering*, 38(6), 1808–1819. <https://doi.org/10.1016/j.compeleceng.2012.09.001>
- Kawale, J., Pal, A., & Srivastava, J. (2009). Churn Prediction in MMORPGs: A Social Influence Based Approach. In *2009 International Conference on Computational Science and Engineering* (Vol. 4, pp. 423–428). <https://doi.org/10.1109/CSE.2009.80>
- Keramati, A., Jafari-Marandi, R., Aliannejadi, M., Ahmadian, I., Mozaffari, M., & Abbasi, U. (2014). Improved churn prediction in telecommunication industry using data mining techniques. *Applied Soft Computing*, 24, 994–1012. <https://doi.org/10.1016/j.asoc.2014.08.041>
- Keramati, Abbas, & Ardabili, S. M. S. (2011). Churn analysis for an Iranian mobile operator. *Telecommunications Policy*, 35(4), 344–356. <https://doi.org/10.1016/j.telpol.2011.02.009>
- Kim, K., Jun, C.-H., & Lee, J. (2014). Improved churn prediction in telecommunication industry by analyzing a large network. *Expert Systems*

- with *Applications*, 41(15), 6575–6584.
<https://doi.org/10.1016/j.eswa.2014.05.014>
- Kim, N., Jung, K.-H., Kim, Y. S., & Lee, J. (2012). Uniformly subsampled ensemble (USE) for churn management: Theory and implementation. *Expert Systems with Applications*, 39(15), 11839–11845.
<https://doi.org/10.1016/j.eswa.2012.01.203>
- Kirui, C., Hong, L., Cheruiyot, W., & Kirui, H. (2013). Predicting Customer Churn in Mobile Telephony Industry Using Probabilistic Classifiers in Data Mining, *10*(2), 165–172.
- Kisioglu, P., & Topcu, Y. I. (2011). Applying Bayesian Belief Network approach to customer churn analysis: A case study on the telecom industry of Turkey. *Expert Systems with Applications*, 38(6), 7151–7157.
<https://doi.org/10.1016/j.eswa.2010.12.045>
- Kotler, P. (2003). *Marketing Insights from A to Z*. New Jersey.
- Kumar, V., & Petersen, J. A. (2012). *Statistical Methods in Customer Relationshipmanagement*. John Wiley & Sons, Ltd.
- Lin, W.-C., Tsai, C.-F., & Ke, S.-W. (2014). Dimensionality and data reduction in telecom churn prediction. *Kybernetes*, 43(5), 737–749.
<https://doi.org/10.1108/K-03-2013-0045>
- Linoff, G. S., & Berry, M. J. A. (2004). *Data Mining Tecniques For Marketing, Sales and Customer Relationship Management* (Second Edition). Indianapolis: Wiley Publishing Inc.
- M. Accardi-Petersen. (2011). *Agile Marketing*. New York: Apress.
- Miguéis, V. L., Van den Poel, D., Camanho, A. S., & Falcão e Cunha, J. (2012). Modeling partial customer churn: On the value of first product-category purchase sequences. *Expert Systems with Applications*, 39(12), 11250–11256. <https://doi.org/10.1016/j.eswa.2012.03.073>
- Moeyersoms, J., & Martens, D. (2015). Including high-cardinality attributes in predictive models: A case study in churn prediction in the energy sector. *Decision Support Systems*, 72, 72–81.
<https://doi.org/10.1016/j.dss.2015.02.007>
- Nettleton, D. (2014). *Commercial Data Mining: Processing, Analysis and Modeling for Predictive Analytics Projects* (1st ed.). San Francisco, CA, USA: Morgan Kaufmann Publishers Inc.
- Saradhi, V. V., & Palshikar, G. K. (2011). Employee churn prediction. *Expert Systems with Applications*, 38(3), 1999–2006.
<https://doi.org/10.1016/j.eswa.2010.07.134>

- Sharma, A., & Panigrahi, D. P. K. (2011). A Neural Network based Approach for Predicting Customer Churn in Cellular Network Services. *International Journal of Computer Applications*, 27(11), 26–31. <https://doi.org/10.5120/3344-4605>
- Tamaddoni Jahromi, A., Stakhovych, S., & Ewing, M. (2014). Managing B2B customer churn, retention and profitability. *Industrial Marketing Management*, 43(7), 1258–1268. <https://doi.org/10.1016/j.indmarman.2014.06.016>
- Tsai, C.-F., & Lu, Y.-H. (2009). Customer churn prediction by hybrid neural networks. *Expert Systems with Applications*, 36(10), 12547–12553. <https://doi.org/10.1016/j.eswa.2009.05.032>
- Tsiptsis, K., & Chorianopoulos, A. (2009). *Data Mining Techniques in CRM: Inside Customer Segmentation*. John Wiley & Sons, Ltd.
- Vafeiadis, T., Diamantaras, K. I., Sarigiannidis, G., & Chatzisavvas, K. C. (2015). A comparison of machine learning techniques for customer churn prediction. *Simulation Modelling Practice and Theory*, 55, 1–9. <https://doi.org/10.1016/j.simpat.2015.03.003>
- Verbeke, W., Martens, D., & Baesens, B. (2014). Social network analysis for customer churn prediction. *Applied Soft Computing*, 14, Part C, 431–446. <https://doi.org/10.1016/j.asoc.2013.09.017>
- Wei, C.-P., & Chiu, I.-T. (2002). Turning telecommunications call details to churn prediction: a data mining approach. *Expert Systems with Applications*, 23(2), 103–112. [https://doi.org/10.1016/S0957-4174\(02\)00030-1](https://doi.org/10.1016/S0957-4174(02)00030-1)
- Xie, Y., & Li, X. (2008). Churn prediction with Linear Discriminant Boosting algorithm. In *2008 International Conference on Machine Learning and Cybernetics* (Vol. 1, pp. 228–233). <https://doi.org/10.1109/ICMLC.2008.4620409>
- Zhao, Y., Li, B., Li, X., Liu, W., & Ren, S. (2005). Customer Churn Prediction Using Improved One-class Support Vector Machine. In *Proceedings of the First International Conference on Advanced Data Mining and Applications* (pp. 300–306). Berlin, Heidelberg: Springer-Verlag. https://doi.org/10.1007/11527503_36