

Müşteri Krediverilebilirliğini Psikometrik Ölçek ve Yapay Öğrenme ile Modellemek

Modeling Consumer Creditworthiness via Psychometric Scale and Machine Learning

Türkay Şahin

*Psikoloji
MEF Üniversitesi
İstanbul, Türkiye
sahintur@mef.edu.tr*

Tuna Çakar

*Bilgisayar Mühendisliği
MEF Üniversitesi
Tam Finans A.Ş.
İstanbul, Türkiye
cakart@mef.edu.tr*

Tunahan Bozkan

*Bilişim Teknolojileri
MEF Üniversitesi
Tam Finans A.Ş.
İstanbul, Türkiye
bozkant@mef.edu.tr*

Seyit Ertuğrul

*Bilişim Teknolojileri
MEF Üniversitesi
Tam Finans A.Ş.
İstanbul, Türkiye
seyitertugrul@tamfinans.com.tr*

Alperen Sayar

*Bilişim Teknolojileri
MEF Üniversitesi
Tam Finans A.Ş.
İstanbul, Türkiye
sayara@mef.edu.tr*

Öz—Müşterilerin krediverilebilirliğini tespit etmek için kullanılan ekonomik metriklerin tahmin gücü yüksek olmasına rağmen, son yıllarda bilişsel, psikolojik, davranışsal, alternatif ve demografik verilerin kredi risk sistemlerine entegre edilmesi ve ilgili verilerin daha modern yöntemlerle işlenmesine olan ilgi artmıştır. Farklı verilerle kredi risk sistemlerinin müşteri sınıflandırma kesinliğinin artması bu ilginin arkasındaki temel motivasyonlardan biridir. Bu araştırmada; karakter, para tutumu, dürüstlük, benlik sayacı, özdenetim ve materyallere atfedilen değerler aracılığı ile müşterilerin krediverilebilirliği yapay öğrenme yöntemleri kullanılarak modellenmiştir ve elde edilen bulgular sonraki çalışmalar için referans seviyesi oluşturacak seviyedendir.

Anahtar Sözcükler — faktöring; yapay öğrenme; krediverilebilirlik; alternatif veri kaynakları.

Abstract— Although the predictive power of economic metrics to detect the creditworthiness of the customers is high, there is a rising interest in the integration of cognitive, psychological, behavioral, alternative, and demographic data into credit risk systems and processing the data through modern methods. The primary motivation for the rising interest is increased customer classification accuracy. In this research, customer creditworthiness was modeled through data consisting of

personality, money attitudes, impulsivity, self-esteem, self-control, and material values and processed through artificial intelligence. The obtained findings have been evaluated as a reference point for the following research.

Keywords — factoring; artificial learning; creditworthiness; alternative data sources.

I. Giriş

Finansal şirketler (örn., faktöring şirketleri, bankalar) müşterinin krediverilebilirliğine karar vermek amacıyla, geçmiş geri ödeme verilerine dayanan kredi risk raporuna (KRP) dayanma eğilimindedirler. KRP'nin doğruluğu yüksek olmasına rağmen, potansiyel müşterilerin finansal risk profilleri alternatif verilerin (örn., davranışsal, bilişsel, durumsal, demografik, psikolojik) KRP'ye entegre edilmesiyle [4, 8, 9, 13, 17] ve verilerin karar ağacı, yapay öğrenme, yapay sinir ağları gibi güncel bilgisayarlı sistemlerle analiz edilmesi ile doğruluğun artırılabileceği bilinmektedir [2, 3, 5]. Finansal şirketlerin krediyi, ödemeyecek bireylere vermesi ve krediyi zamanında ödeyebilecek müşterilere kredi vermemesi hem finansal şirketlere zarar vermekte hem de yeni küçük ve orta ölçekli işletmelerin kurulmasının önüne geçmektedir. Kredi risk

modellerinde bulunan bu hataların çok düzeyli zararlı etkileri (örn., bireysel, kurumsal, toplumsal) göz önünde bulundurulduğunda, doğruluğu daha yüksek kredi risk modelleri kurmanın önemi göze çarpmaktadır.

Harvard İşletme Okulu bünyesinde 2006 yılında Bailey Klinger ve Asim Khwaja tarafından kurulan Girişimci Finans Laboratuvarı (GFL, Entrepreneurial Finance Lab) psikometrik yöntemler ile kredi risk tahmini yapılması alanında dünyada öncüdür. GFL; Latin Amerika, Asya ve Afrika'daki iş birlikleri ile toplamda bir milyar Amerikan dolarını aşan bir miktarın bireylere verilebilmesini veya ilgili meblağın daha iyi kullanılabılmesini sağlamıştır [7]. GFL, psikometrik bağlamda, kişilik, dürüstlük, akişkan zekâ, işlem belleği ve demografik değişkenleri kullanarak girişimcilerin iş kârlılığını ve borç geri ödeme durumlarını incelemiştir. Araştırmmanın sonuçlarına göre, dışadönüklük ve uyumluluk daha yüksek iş kârlılığı ile, yeni deneyimlere açıklık daha düşük iş kârlılığı ile ve duygusal dengeliğin düşük borç geri ödememe riski ile ilişkilendirilmiştir. Diğer yandan dürüstlük daha düşük iş kârlılığı ve düşük borç geri ödememe riski ile, işlem belleği daha düşük iş kârlılığı ile ve akişkan zekâ daha yüksek iş kârlılığı ve daha yüksek borç geri ödememe riski ile ilişkilendirilmiştir. Eğitim durumu ise daha yüksek iş kârlılığı ve daha yüksek borç geri ödememe riski ile ilişkilendirilmiştir [13]. GFL tarafından geliştirilen psikometrik kredi risk modeli şu an için altın standart olarak değerlendirilirse de bu modelin her zaman istenilen performansı göstermediği başka araştırmalar tarafından gösterilmiştir [1, 20].

Baklouti [2] mikro finans enstitülerindeki borç geri ödeme davranışını incelemek üzere Tunus Mikrofinans Bankasından veri toplamış ve karar ağacı adı verilen parametrik olmayan yöntemler ile ilgili verileri analiz etmiştir. Duygusal zekâ başta olmak üzere, bireylerin psikolojik özellikleri sayesinde, ödenmesi güç borçların %3,125 oranında azaltılabileceği saptanmıştır. Benzer şekilde, Rogers ve diğerleri [17] 55 çeşit sosyodemografik, 6 çeşit durumsal, 25 çeşit psikolojik ve 10 çeşit davranışsal veriye dayanarak bireylerin borç geri ödeymeme durumlarını tahmin etmek amacıyla kapsamlı bir model geliştirmiştir. Demografik ve durumsal değişkenler arasından doğrudan bireylerin finansal durumlarına etki edebilecek değişkenler (örnek., ev sahibi olma, eşin mesleği, eşin ve ailenin geliri, birlikte yaşanan insan sayısı, medeni durum; kredi kartı sayısı, finansal zorluk yaşama); psikolojik değişkenler arasından paraya atfedilen değer, kendini yeterli hissetme, kompulsif satın alma pratikleri sergileme ve bazı davranışsal değişkenlerin anlamlı bir tahmin gücüne sahip olduğu saptandı. Benzer şekilde, Ganbat ve diğerleri [8] etkili karar verme, özdenetim, sorumluluk, diğergamlik ve kişilerin para karşısında takındığı tavırın anlamlı bir şekilde kredi geri ödeme davranışını tahmin edebildiğini saptadı.

Djeundje ve diğerleri [4] kredi geçmişine alternatif olarak kullanılabilecek 10 adet demografik, 12 adet alternatif ve 22 adet psikolojik değişken ile katılımcıların kredi riskini, makine öğrenmesi dahil olmak üzere birkaç istatistiksel yöntem aracılığı ile tahmin etmeye çalıştı. Demografik değişkenlerden, kişiye finansal olarak bağımlı kaç kişinin olduğu, kişinin haftada kaç saat çalıştığı, cinsiyeti ve yaşı cinsiyet istatistiksel etkileşimi; psikometrik verilerden kişinin başka banka veya finansal kuruluşlarda hesabı olup olmadığı, finansal olarak hazırlı erteleme eğilimi, kişiye referans olabilecek birey sayısı, yaşadığı

muhitte kaç kişinin hırsızlık yaptığı; kişinin henüz sahip olmadığı fakat 12 ay içerisinde sahip olmak istediği ürünlerden kredi kartı, konut kredisi, araç kredisi, mevduat hesabı, bireysel kredi, iş kredisi ve hiçbiri seçeneği; kişinin rastgele elde ettiği belirli bir mikarda parayı nerele yatarmak istediği, katılımcının cevap verirken ne kadar süre harcadığının ortanca değeri ve tekrarlanan sorulara verilen cevapların birbirlerine benzerliği; alternatif verilerden son 2.000 e-postanın kaç yılda gönderildiği, kişinin son 2.000 e-postasını kaç farklı kişiye gönderdiği, kişinin 0-600 saat arasında gönderdiği e-postaların fraksiyonu; salı, perşembe, cumartesi ve pazar günleri gönderilen e-postaların fraksiyonları kredi riskini anlamlı bir şekilde tahmin edebildi. Sonuçlar, en yüksek kesinlige sahip modelin, demografik, alternatif ve psikolojik değişkenlerin hepsinin yer aldığı model olduğunu gösteriyor.

Bu araştırmmanın amacı, kredi risk verisi olmayan veya mevcut kredi risk verisi olumsuz olan bireyleri kredi sahibi yapmak için kullanılabilecek, hızlı ve güvenilir bir psikometrik kredi risk modeli oluşturmaktır.

II. YÖNTEM

A. Katılımcılar

Tam Finans'tan kredi kullanmış ve halihazırda kredi risk geçmişi bilinen 110 kişi araştırmaya gönüllü olarak katılım göstermiştir.

B. Materyaller

1) *Büyük Beş Kişilik Envanteri*: Goldberg [10] yeni deneyimlere açıklık, sorumluluk, dışadönüklük, uyumluluk ve duygusal dengesizliği ölçme amacıyla Büyük Beş Kişilik Envanteri'ni geliştirdi. Büyük Beş Kişilik Envanterinde her boyut için 10 ifade, toplamda ise 50 ifade bulunmaktadır. Her ifade (örn., "Olayları zihnimde canlandırıyorum.") 5'li Likert ölçeğinde puanlanmaktadır (1 = Hiç uygun değil, 5 = çok uygun). Tatar [22] Büyük Beş Kişilik Envanteri'ni Türkçe'ye çevirmiştir ve yeni deneyimlere açıklık dışındaki her boyutun güvenilirlik değeri yeterli seviyelere ulaşmıştır (duygusal dengesizlik için $\alpha = 0.760$; dışadönüklük için $\alpha = 0.757$; uyumluluk için $\alpha = 0.731$; sorumluluk için $\alpha = 0.794$; yeni deneyimlere açıklık için $\alpha = 0.678$).

2) *Barratt Dürütüsellik Ölçeği*: Patton ve diğerleri [15] dörtüselligin altı boyutunu ölçmek üzere (dikkat, motor, öz-kontrol, bilişsel karmaşıklık, sebat, bilişsel istikrarsızlık) Barratt Dürütüsellik Ölçeği-11'i geliştirmiştir. Maddeler (örn., "Düşünürken sıkılıkla zihnimde konuya ilgisiz düşünceler oluşur.") 4'lü Likert ölçeğinde puanlanmaktadır (1 = Nadiren/hiçbir zaman, 4 = hemen her zaman/her zaman). Güleç [11], Barratt Dürütüsellik Ölçeğini Türkçeye çevirmiştir ve güvenilirlik değeri yeterli seviyelere ulaşmıştır (lisans öğrencileri için $\alpha = 0.780$; psikiyatrik bireyler için $\alpha = 0.810$).

3) *Rosenberg Benlik Saygısı Ölçeği*: Rosenberg [19] 10 maddeden oluşan Rosenberg Benlik Saygısı Ölçeğini geliştirmiştir. Maddeler (örn., "Kendimde gurur duyacak fazla bir şey bulamıyorum.") 4'lü Likert ölçeğinde puanlanmaktadır

(1 = Çok yanlış, 4 = çok doğru). Çuhadaroğlu (as cited in [14]), ölçüği Türkçe'ye adapte etmiştir.

4) *Para Tutum Ölçeği*: Yamauchi ve Templar [25] 29 maddeden oluşan ve bireylerin paraya atfettiği değerleri ölçmek üzere Para Tutum Ölçeğini geliştirmiştir. Maddeler (örn., "En temel ihtiyaçlarım için bile para harcarken tereddüt ederim.") 5'li Likert ölçeğinde puanlanmaktadır (1 = Hiçbir zaman, 5 = her zaman). Ölçeğin Türkçe çevirisini Süer ve diğerleri [21] tarafından edindik.

5) *Özdenetim Ölçeği*: Rosenbaum [18] 36 maddeden oluşan ve öz-denetimin yaşantısal, yenileyici ve onarıcı boyutlarını ölçen Öz-Denetim Ölçeğini geliştirmiştir. Maddeler (örn., "Bir yerim ağrısında, düşüncelerimi başka yöne çevirmeye çalışıyorum.") 6'lı Likert ölçeğinde puanlanmaktadır (-3 = Bana tamamen uyumuyor, +3 = bana tamamen uyuyor). Duyan ve diğerleri [6] Özdenetim Ölçeğini Türkçeye çevirmiştir ve ölçeğin güvenirlik değeri yeterli seviyelere ulaşmıştır (yaşantısal öz-denetim için $\alpha = 0.836$; yenileyici öz-denetim için $\alpha = 0.758$; onarıcı öz-denetim için $\alpha = 0.725$).

6) *Materyal Değerler Ölçeği*: Richins ve Dawson [16] 18 maddeden oluşan ve materyal değerlerin başarı, merkezilik ve mutluluk boyutlarını ölçen Materyal Değerler Ölçeğini geliştirmiştir. Maddeler (örn., "Sahip olduğum maddi varlıklar hayatı ne kadar iyi şeyler yaptığımı anlatır.") 5'li Likert ölçeğinde puanlanmaktadır (1 = Hiç katılmıyorum, 5 = tamamen katılıyorum). Ünal [23] Materyal Değerler Ölçeğini Türkçeye adapte etmiştir ve ölçeğin güvenirlik değeri yeterli seviyelere ulaşmıştır ($\alpha = 0.733$).

C. Deneysel prosedür

Öncelikle, altı farklı psikolojik ölçeğin maddelerinden oluşan bir havuz oluşturuldu. Toplamda 173 adet madde vardı ve her madde olumlu (örn., sorumluluk, özdenetim, benlik saygı) ve olumsuz (örn., güç-prestij, dışadönünlük, uyumluluk) finansal çıktıların göstergesi olarak etiketlendi. Her ölçek ve boyut için keşifsel faktör analizi yapıldı ve temsil gücü en yüksek maddeler işaretlendi. Sonrasında, müşteriler temsilcileri, maddeler arasından müşterilerin demografik özellikleri ve müşteriler ile olan birebir iletişimlerini göz önünde bulundurarak en uygun maddeleri seçti. Her psikometrik sıralama bazlı soru, üç olumlu ve üç olumsuz finansal çıktılarla ilişkilendirilmiş altı şıkka sahipti. Olumlu ve olumsuz şıkların seçiminde, şıkların kredi ödemeyle olan etkisinin, katılımcılar tarafından anlaşılmamasına özen gösterildi. Modelin son hali beş adet sıralama bazlı psikometri ve üç adet finansal okuryazarlık sorusundan oluşuyordu. Veri toplama sürecinden sonra, müşteriler temsilcileri, müşteriler ile olan birebir iletişimlerini ve müşterilerin geri ödeme başarısını göz önünde bulundurarak, müşterileri bir ile üç (1 = düşük krediverilebilirlik, 2 = orta krediverilebilirlik, 3 = yüksek krediverilebilirlik) arasında puanladı. Müşteri temsilcilerinden elde edilen skorlar bağımlı değişken olarak kullanıldı. Araştırma yaklaşık beş dakika sürdü. Veri toplama süreci boyunca Qualtrics (<https://qualtrics.com/>) platformu kullanıldı.

III. MODEL GELİŞTİRME

A. Veri setinin hazırlanması

Veri setinin hazırlanması aşamasında Tam Finans Şirketi'nde 2020 yılının Haziran ayı ile 2020 yılının Ağustos ayı arasında rastgele seçilmiş 146 adet müşterinin psikometrik anket sonuçları kullanılmıştır. Ham veri setinde 146 adet gözlem bulunmaktadır. Proje çıktılarına uygunluk açısından anketi tamamlamayan 36 kişi veri setinden çıkarılarak 110 adet gözleme düşürülmüştür. Veri setinin hedef değişkeni, müşteri temsilcilerinin müşterilere verdiği, 1'den 3'e kadar olan (1, 2, 3) değerlendirme puanlarıdır. Sınıflandırma kriteri ise ödemeden ödere doğru sayısal olarak artmaktadır. Toplanan verilerin 67 adeti 3, 38 adeti 2 ve 5 adedi 1 olarak müşteri temsilcileri tarafından sınıflandırılmıştır. Elde edilen veri setinde toplam 113 adet gözlem ve 53 adet öznitelik bulunmaktadır.

B. Veri analizi ve önişleme

Krediverilebilirliğinin analizi için veri setinin elde edilmesinden sonra ilk olarak 1 olan sınıfın gözlem sayısının yetersiz olması sebebiyle 1. sınıfı ait veriler 2. sınıf ile birleştirilmiştir. Bunun sonucunda hedef değişken sayısı 2'ye indirilmiştir. Bununla birlikte toplamda 67 adet 2. sınıfта 43 adet 1. sınıfta veri bulunmaktadır. Veri seti için gerekli dönüşümler yapıldıktan sonra öznitelik tiplerinin kontrolü sağlandı. Veri seti üzerinden öznitelik analizi gerçekleştirilmiş ve öznitelik tipleri tanımlanmıştır. Öznitelikler sayısal, kategorik ve tarih değerleri içermektedir. Bazı özniteliklerin tespit edilen veri tipi olması gerekenden farklı olduğu için öznitelik tipleri dönüştürülmüştür. Veri setinde çok fazla gözlem olmaması ve müşterilere yapılan anketelerin tarih aralığı kısa olması sebebiyle tarih değeri içeren öznitelikler çıkarılmıştır. Veriler üzerinde yapılan betimleyici istatistikler ile veri setindeki boş değerler tespit edilmiştir. Elde edilen sonuçta 3 müşteri için sınıf ataması gerçekleşmediğinden ve bazı diğer değerlerinin boş olması sebebiyle bu 3 müşteri veri setinden çıkarılmıştır. Veri setinden eksik gözlemlerin ve kullanılmayacak olan özniteliklerin çıkarılması sonucunda 110 gözlem ve 31 adet öznitelik kalmıştır. Bu öznitelikler müşterilerin anket sorularına verdikleri yanıtların sıralamasını içermektedir. Genel olarak, kullanılan makine öğrenmesi modelleri kategorik değişken kabul etmemesi sebebiyle kategorik öznitelikler üzerinde kodlama (encode) yapılarak sayısal verilere dönüştürülmüştür. Kategorik değişkenlerin kodlanması için 15 farklı yöntem uygulanmıştır. Bu yöntemlerden bazları: Kanıtların Ağırlığı (WOE), Hedef değişkene göre kodlama (Target Encoding), İkili kodlama (Binary Encoding), Hash kodlama, James-Stein ve Helmert gibi kodlama yöntemleridir. Çeşitli encoding yöntemleri sonrasında elde edilen öznitelikler ve hedef değişken arasındaki korelasyon sonucunda Target Encoding yönteminin kullanılmasına karar verilmiştir.

Makine öğrenimi modellerinin genel olarak kabul ettiği varsayımlara da ayrıca dikkat edildi. Bunlar lineer olma durumu, homoskedastisite, normal dağılım ve çoklu bağlantı (multicollinearity) durumudur. Modellerin genel varsayımların en az düzeyde dahi karşılanabilmesi için gerekli ön testler yapıldı ve sonrasında veri setleri üzerinde, test sonuçlarıyla ilişkili olarak gerekli görülen değişiklikler uygulandı. Çoklu bağlantı durumu için korelasyon matrisi kullanılarak birbirleri arasında %90'dan daha fazla ilişki bulunan özniteliklerden bir

tanesi ya çıkarıldı ya da birleştirme mümkün ise özniteliklerden yeni bir öznitelik elde edilerek kullanıldı. Veri setlerindeki değerlerin normallige yakınlığını kontrol etmek için histogram grafiği ve Kolmogorov-Smirnov testi kullanıldı. Değişkenlerin dağılıminın analiz edilebilmesi için farklı analiz ve test yöntemleri kullanıldı. Ayrik değişkenler için Binom dağılımı kullanılırken sürekli değişkenler için Gauss dağılımı ve Çarpıklık analizi gerçekleştirildi. Verileri normalize etmek için logaritmik dönüşüm, karekök dönüşümü ve yeo-johnson dönüşüm yöntemleri kullanıldı. Uygulanan normalizasyon sonrasında veri setlerinde bulunan farklı özniteliklerin aynı değer aralıklarına getirilmesi gerekmektedir. Soru bazlı seçenek sayısının değişmesi sebebiyle elde edilen sayısal değişkenlere sonrasında standartlaştırma işlemi yapılmıştır. Uygulanan normalizasyon sonrasında veri setlerinde bulunan farklı özniteliklerin aynı değer aralıklarına getirilmesi gerekmektedir. Bu ölçeklendirme hem kümeleme hem de akabinde gerçekleştirilecek modelleme için oldukça önemlidir. Ölçeklendirme işlemi için Standartlaştırma, Min-Max ölçeklendirme ve güçlü (robust) ölçeklendirme yöntemleri uygulandı. Uygulanan yöntemlerin analizi sonrasında Min-Max ölçeklendirme yöntemi kullanıldı.

C. Model geliştirme

Veri seti üzerindeki detaylı analizler sonrasında model geliştirme kısmına geçilmiştir. Hedef değişkeninin sürekli olmaması sebebiyle gözetimli makine öğrenimi modelleri kullanıldı. Modelleme aşamasında birden çok model denendi. Kullanılan modellerin sonuçları karşılaştırılarak en iyi model seçili işlemelere devam edildi. Kullanılan modeller: Destek Vektör Makineleri, (SVM) XGBoost, Lojistik Regresyon, Rassal Ormanlar, Karar Ağaçları ve k-En Yakın Komşular'dır. Veri setleri üzerinde yapılan analizler sonucunda hedef değişkene bağlı olarak veri setinin dengesiz olduğu tespit edildi. Verilerin %39'u 1. sınıfı ait müşteri iken %61'i 2. sınıfı aittir. Yüksek oranda bir dengesizlik olmamasına rağmen dengesiz veri seti problemi çözümü için birkaç yol denendi. Bunlar örnek azaltımı (undersampling), örnek artırımı (oversampling) ve sınıf ağırlığı (class-weight) dengelemesidir. Örnek azaltımı sonucunda modellerin başarı oranlarında herhangi bir gelişim olmayıp aksine model başarım ortalamasında %7-%9 oranında azalma olmuştur. Buna ek olarak gözlem sayısının az olması sebebiyle bu yöntem tercih edilmemiştir. Sınıf ağırlığı dengelemesi tespiti sonucunda modellerin genel doğruluk oranlarında herhangi bir artış görülmemiştir ve bu yöntem tüm makine öğrenimi modellerinde kullanılmamaktadır. Örnek artırımı yöntemi sonrasında tüm modellerin genel doğruluk ve F1- Skorlarında %2-%3 iyileştirme elde edilmiştir. Bu sebepten ötürü örnek artırımı uygulanmıştır. Modellerin sonuçlarının güvenilir olması ve daha test edilebilir ve kullanılabilir olması için çapraz doğrulama (cross validation) yöntemine başvuruldu. Bu aşamada tüm gözlemlerin %65'i eğitim seti, %35'ü ise test seti olarak kullanıldı. Çapraz doğrulama aşamasında çapraz doğrulama kat sayısı veri setinin büyklüğüne bağlı olarak 5 seçildi. Model sonuçlarının elde edilmesi sonucunda analiz için sadece doğruluk oranı kullanılmıştır. Kullanılan modellerde Lojistik Regresyon'a ait sınıflandırma raporu Şekil 2'de ve karmaşıklık matrisi ise Şekil 3'te belirtilmiştir. Skorlama metriklerinden F-1 Skoru, ROC-AUC eğrisi, Kesinlik (Precision) ve Hassaslık (Recall) metrikleri kullanılmıştır. Verisetine her ne kadar örnek artırımı yöntemi uygulanmış olsa

da model sonuçlarının analizi ve sınıfların doğruluk oranları farklı olması sebebiyle ROC-AUC eğrisi kullanılarak sınıflar arası doğruluk oranı ayarlanması için kullanılmıştır. ROC-AUC eğrisi ile birlikte eşik değeri (threshold) belirlenerek en yüksek F-1 Skoru seçilmeye çalışılmıştır. Eşik değeri ayarlanması sonrasında modellerin doğruluk oranı artırımı için izgara araması (Grid Search) yöntemi farklı modellere farklı parametreler ile uygulanmıştır. Grid Search işlemlerinde en yüksek F1-Skoruna sahip model olan XGBoost yöntemi için yapılmıştır. XGBoost parametreleri 3 farklı kategoride toplanmıştır. Bunlar genel parametreler, booster parametreleri ve öğrenme görevi parametreleridir (learning task parameters). Genel parametrelerin içinden 1 adet parametre (booster parametresi) kullanılmıştır. Silent ve nthread parametreleri kullanılmamıştır. Booster parametresi 'gbtree' ve 'gblinear' özelliklerini almaktadır. Booster parametrelerinden min_child_weight, max_depth, max_leaf_node ve learning rate parametreleri kullanılmıştır. Eta parametresi leraning reate (öğrenme hızını) kapsamaktadır. Hiper parametre ayarlamaları sonucunda optimal değerler Çizelge I'de belirtilmiştir.

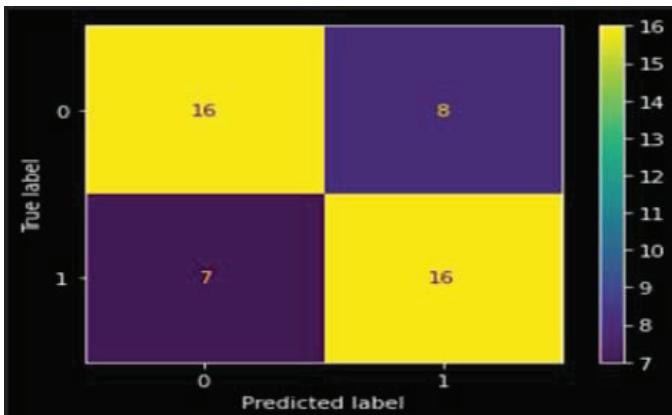
ÇİZELGE I. PARAMETRELER VE DEĞERLER

Parametre	Verilen Değerler	Optimal Değer
booster	gbtree, gblinear, dart	gbtree
learning_rate	0.001, 0.002, 0.005, 0.01, 0.02, 0.05, 0.1, 0.5	0.05
max_depth	1, 2, 3, 5, 6, 10, 15, 20	5
min_child_weight	1, 2, 3, 5, 6, 10, 15, 20	3
gamma	0, 1, 2, 5	0
n_estimator	5, 10, 20, 100, 200, 500	100
reg_alpha	1e-5, 1e-2, 0.1, 1, 100	1

Hiper parametre optimizasyonu sonucunda XGBoost modeli ile elde edilen sonuçlar Şekil 3 ve 4'de belirtilmiştir. Çizelge I'de hiperparametre sonuçları sonucunda sınıflandırma raporu verilmiştir. Şekil 4'de oluşturulan modelin karmaşıklık matrisi belirtilmiştir.

The accuracy of model XGBClassifier is 0.68				
	precision	recall	f1-score	support
0	0.70	0.67	0.68	24
1	0.67	0.70	0.68	23
accuracy			0.68	47
macro avg	0.68	0.68	0.68	47
weighted avg	0.68	0.68	0.68	47

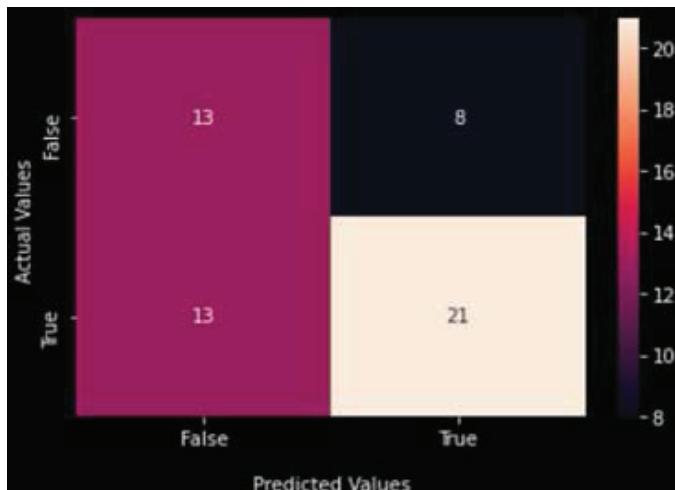
Şekil 1. XGBoost Sınıflandırma Raporu



Şekil 2. XGBoost Karmaşıklik Matrisi

	precision	recall	f1-score	support
0	0.50	0.62	0.55	21
1	0.72	0.62	0.67	34
accuracy			0.62	55
macro avg	0.61	0.62	0.61	55
weighted avg	0.64	0.62	0.62	55

Şekil 3. Lojistik Regresyon Sınıflandırma Raporu



Şekil 4. Lojistik Regresyon Karmaşıklik Matrisi

IV. SONUÇ VE TARTIŞMA

Bu araştırmada, yapay öğrenme yöntemlerini kullanarak, Tam Finans bünyesinde kredi kullanmış 110 müşteri ile psikometrik kredi risk modeli test edilmiştir. Model geliştirme aşamalarında uygulanan yöntemler sonrasında en iyi sonuç XGBoost yöntemi ile elde edilmiş ve doğruluk karşılaştırılmış Şekil 2' te gösterilmiştir. Şekil 2' de ve Şekil 4'te eğitilen XGBoost ve Logistik Regresyon modelleri sonucunda oluşan test verisi üzerindeki karmaşıklik matrisleri (Confusion Matrix) verilmiştir. Yapılan sonuçlarda uygulanan testler ile kredi verilebilirliği ölçümlerinde %68 başarım oranına ulaşılmıştır.

Model karşılaştırması sonuçları Çizelge II'de belirtilmiştir. Elde edilen %68'lik başarım oranı, yalnızca psikometrik veri göz önünde bulundurulduğunda, bazı araştırmalara göre yüksektir [4].

ÇİZELGE II. MODEL SONUÇLARI KARŞILAŞTIRMALARI

Model		Precision	Recall	F1 - Skor
<i>XGBoost</i>	<i>Sınıf 0</i>	0.70	0.67	0.68
	<i>Sınıf 1</i>	0.67	0.70	0.68
<i>Lojistik Regresyon</i>	<i>Sınıf 0</i>	0.50	0.62	0.55
	<i>Sınıf 1</i>	0.72	0.62	0.67
<i>SVM</i>	<i>Sınıf 0</i>	0.63	0.62	0.62
	<i>Sınıf 1</i>	0.61	0.60	0.61
<i>Rassal Ormanlar</i>	<i>Sınıf 0</i>	0.54	0.73	0.62
	<i>Sınıf 1</i>	0.69	0.61	0.65
<i>kNN</i>	<i>Sınıf 0</i>	0.63	0.57	0.60
	<i>Sınıf 1</i>	0.60	0.59	0.60
<i>Karar Ağaçları</i>	<i>Sınıf 0</i>	0.55	0.70	0.62
	<i>Sınıf 1</i>	0.68	0.60	0.64

Önceki alternatif verilere dayanan kredi risk modelleri göz önünde bulundurulduğunda [4, 8, 9, 13, 17], bu araştırma dahilinde geliştirilen psikometrik kredi risk modeli çok daha kısa sürede bireylerin krediverilebilirliğine dair güvenilir iç görüller sağlayabilmektedir. Bunun yanı sıra, kredi almak isteyen müşteriler, finans şirketi bağlamında psikometrik kredi risk testleri ile karşılaşlıklarını takdirde, kendileri hakkında olduklarından daha iyi bir çizelge çizmeye çabalayabilirler. Bu durumun önüne geçmek adına, potansiyel müşterilerin ölçek maddelerinin kredi risk ödeme tahminini hangi yönde etkilediğini tahmin edememeleri büyük bir önem taşımaktadır. Bu araştırma dahilinde geliştirilen psikometrik sorularının içinde yer alan maddeler, müşterilerin bu tahmini başarılı bir şekilde yapamayacağı şekilde seçilmiştir.

Bu araştırmada sağlanan psikometrik kredi risk tahmin oranı bazı araştırmalara kıyasla daha yüksek olmasına rağmen, KRP'ye entegre edilecek psikometrik modellerin daha kesinlikli sonuçlar sağlama kritik önem taşımaktadır. Bu sebeple, anketin çözülme süresini çok uzatmaksızın, psikometrik kredi risk modellerine başka tür verilerin (örn., davranışsal ve durumsal) de eklenmesi model kesinliğini de olumlu yönde etkileyecektir. Ayrıca, bu eklemeler ile elde edilecek model, geniş kitleler üzerinde, detaylı bir müşteri segmentasyonu ile birlikte tekrar test edilmeli ve psikolojik özelliklerin krediverilebilirliğine olan etkisi, segmentler bazında da saptanmalıdır.

KAYNAKÇA

- [1] I. Arráiz, M. Bruhn, and R. Stucchi, "Psychometrics as a tool to improve credit information.", *The World Bank Economic Review*, 30(Supplement_1):67-76, 2017.
- [2] I. Baklouti, "A psychological approach to microfinance credit scoring via a classification and regression tree", *Intelligent Systems in Accounting, Finance and Management*, 21(4):193-208, 2014.
- [3] D. Van Thiel and W. F. F. Van Raaij, "Artificial intelligence credit risk prediction: An empirical study of analytical artificial intelligence tools for credit risk prediction in a digital era", *Journal of Risk Management in Financial Institutions*, 12(3):268-286, 2019.
- [4] V. B. Djeundje, J. Crook, R. Calabrese, and M. Hamid, "Enhancing credit scoring with alternative data", *Expert Systems with Applications*, 163:113766, 2021.
- [5] G. Du, Z. Liu, and H. Lu, "Application of innovative risk early warning mode under big data technology in internet credit financial risk

- assessment" *Journal of Computational and Applied Mathematics*, 386:113260, 1999.
- [6] V. Duyan, Ç. Gülden, and S. Gelbal, "Self-control scale – SCS: Reliability and validity study", *Toplum ve Sosyal Hizmet*, 23(1):19-30, 2012.
- [7] "Entrepreneurial Finance Lab (EFL)," *khwaja.scholar.harvard.edu*. <https://khwaja.scholar.harvard.edu/entrepreneurial-finance-lab-efl>
- [8] M. Ganbat *et al.*, "Effect of Psychological Factors on Credit Risk: A Case Study of the Microlending Service in Mongolia," *Behavioral Sciences*, vol. 11, no. 4, p. 47, Apr. 2021, doi: 10.3390/b11104047.
- [9] R. Ge, J. Feng, B. Gu, and P. Zhang, "Predicting and Deterring Default with Social Media Information in Peer-to-Peer Lending," *Journal of Management Information Systems*, vol. 34, no. 2, pp. 401–424, Apr. 2017, doi: 10.1080/07421222.2017.1334472.
- [10] L. R. Goldberg, "The development of markers for the Big-Five factor structure," *Psychological Assessment*, vol. 4, no. 1, pp. 26–42, 1992, doi: 10.1037/1040-3590.4.1.26.
- [11] F. B. Durmuş, C. Y. Torlak, L. E. Tügen, and H. Güleç, "Psychometric Properties of the Turkish Version of the Barratt Impulsiveness Scale-Brief in Adolescents" *Archives of Neuropsychiatry*, 2021, doi: 10.29399/npa.27527.
- [12] E. Güler and H. Tunahan, "Finansal Okuryazarlık: Hane Halkı Üzerine Bir Araştırma" *İşletme Bilimi Dergisi*, pp. 1–26, Dec. 2017, doi: 10.22139/jobs.323261.
- [13] F. M. Loewenberg, "Poverty in Eighteenth-Century New York City: A Jewish Pauper Demands Kosher Meals," *New York History*, vol. 95, no. 3, pp. 432–445, 2014, doi: 10.1353/nyh.2014.0016.
- [14] S. Özgürler, "Üniversite Öğrencilerinde Benlik Saygısı Düzeyine Göre Kimlik Statüleri ile Başarı Yönelerimleri Arasındaki İlişkinin İncelenmesi," *Pamukkale University Journal of Education*, vol. Ocak, no. 35, pp. 33–33, Jan. 2014, doi: 10.9779/puje543.
- [15] J. H. Patton, M. S. Stanford, and E. S. Barratt, "Factor structure of the Barratt Impulsiveness Scale", *Journal of Clinical Psychology*, 51(6):768-774, 1995.
- [16] M. L. Richins, and S. Dawson, "A consumer values orientation for materialism and its measurement: Scale development and validation", *Journal of Consumer Research*, 19(3):303-316, 1992.
- [17] P. Rogers, D. Rogers, and J. R. Securato, "About Psychological Variables in Application Scoring Models," *Revista de Administração de Empresas*, vol. 55, no. 1, pp. 38–49, Feb. 2015, doi: 10.1590/s0034-759020150105.
- [18] M. Rosenbaum, "A schedule for assessing self-control behaviors: Preliminary findings," *Behavior Therapy*, 11(1):109-121, 1980.
- [19] M. Rosenberg, "Society and the adolescent self-image", Princeton University Press, New Jersey, 1965.
- [20] R. Sifrain, "Does Psychometric Testing in Microfinance Actually Work?—The Case of Sogesol," *Journal of Financial Risk Management*, vol. 09, no. 03, pp. 278–313, 2020, doi: 10.4236/jfrm.2020.93016.
- [21] Ö. Süer, H. F. Baklaç, and E. Kocaer, "Para Tutumunun Kariyer Hedefleri Üzerindeki Etkisi: Üniversite Öğrencileri Üzerinde Bir Araştırma," *Ege Akademik Bakış (Ege Academic Review)*, vol. 17, no. 4, Oct. 2017, doi: 10.21121/eab.2017431301.
- [22] A. Tatar, "Büyük Beş-50 Kişilik Testinin Türkçeye çevirisi ve Beş Faktör Kişilik Envanteri Kısa Formu ile karşılaştırılması," *Anadolu Psikiyatri Dergisi*, 18(1):51-61, 2017.
- [23] S. Ünal, F. Aslay, and Ö. Akbulut, "Materyalizmin statü tüketimini üzerindeki etkisini belirlemeye yönelik bir araştırma," *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 27(2):43-62, 2013.
- [24] "Russian Federation - Financial Literacy Diagnostic Surveys 2008 and 2009 (Panel)," *microdata.worldbank.org*. <https://microdata.worldbank.org/index.php/catalog/1028> (accessed Aug. 26, 2022).
- [25] K. Yamauchi, T. and D. J. Templar, , "The development of a Money Attitude Scale, " *Journal of Personality Assessment*, 46(5):522-528, 1982.