

# Finansal Kurumlarda Senaryo Bazlı Aykırı Gözlem Tespiti: Türk Faktoring Sektörü Üzerine Bir Çalışma

Levent Güntay\*  
Mehmet Aktuna\*\*

## Öz

Finans sektöründe çevrimiçi ve mobil işlemlerin sayısı ve hızının artması beraberinde farklı riskleri ve denetleme maliyetlerini de getirmiştir. Bu riskler sahtecilikten kredi riskine, veri tabanı hatalarından, operasyonel problemler ve müşteri kayıplarına kadar çok farklı alanlarda gerçekleşebilir. Bu çalışmada faktoring işlemleri için senaryo bazlı aykırılık analizi bu riskleri oluşma aşamasında ve gözetimli bir istatistiksel bir model kurmadan tespit etmeyi amaçlamaktadır. Aykırılık analizi bağlamında karakteristikleri ana kümeden büyük sapma gösteren çek, müşteri ya da müşteri temsilcisi gözlemleri aykırı olarak tanımlanmaktadır. Bu karakteristikler faktoring uzmanlarının tecrübelerine dayanılarak geliştirilen senaryo kurguları içinde seçilip bir araya getirilmiştir. Karakteristiklerin ana kümeden sapmaları Mahalanobis, Minimum Kovaryans, ve Ortogonalize Gnanadesikan-Kettenring uzaklıkları ile hesaplanmaktadır. Çalışmada kullanılan veritabanı bir faktoring şirketinin 2018-2020 arası çek faktoring işlem bilgileri ile Kredi Kayıt Bürosu Çek ve Risk raporlarını birleştirmekte ve 7 farklı senaryo kullanılarak aykırı işlemler bulunmaktadır. Kurulan modelin aykırı değer eşik seviyesinin finansal kurumun tolere edebileceği hata tespit oranları ve istihbarat bütçesi çerçevesinde nasıl ayarlanıp optimize edilebileceği de çalışmada gösterilmiştir. Geliştirilen model bankacılık, faktoring, leasing, sigortacılık alanlarındaki hemen her finansal işlemde risk taşıyan aykırı gözlemleri bulabildiği gibi finansal sektörü düzenleyici ve denetleyici kurumlar tarafından da kullanılabilir.

**Anahtar Kelimeler:** Aykırı değer tespiti, Faktoring, Mahalanobis uzaklığı, Sahtecilik tespiti.

**JEL Sınıflandırması:** C10, C38, C55, G21, G23

## Abstract - Scenario Based Anomaly Detection in Financial Institutions: A Study on the Turkish Factoring Sector

The increase in the number and speed of online and mobile transactions in the financial sector generates various risks and monitoring costs. Some of these risks include fraud risk, credit risk, database errors, operational problems and churn risk. In this study, scenario-based anomaly detection analysis for factoring transactions is used to identify these risks at an early stage without establishing a supervised statistical model. In anomaly detection, observations at the check, customer or customer representative level whose characteristics deviate from the main cluster are defined as outliers. The characteristics in scenarios are selected based on the experience of factoring experts. The deviations of the characteristics from the main cluster are calculated by the Mahalanobis, Minimum Covariance, and Orthogonalized Gnanadesikan-Kettenring distances. The data used in this study are comprised of check-level factoring transactions of a factoring company between 2018-2020 and the check and risk reports issued by the Credit Registration Bureau and are detected as outliers by using 7 different risk scenarios. The study also shows that the outlier detection threshold can be optimized within the framework by considering the model errors and the monitoring budget of the financial institution. The developed model can detect risk carrying anomalies in almost every financial transaction in the banking, factoring, leasing, and insurance sectors and can be also employed by the financial regulatory and supervisory institutions.

**Keywords:** Anomaly detection, Outlier detection, Factoring, Mahalanobis distance, Fraud detection.

**JEL Classification:** C10, C38, C55, G21, G23

\* Sorumlu Yazar, Özyeğin Üniversitesi, İşletme Fakültesi, Uluslararası Finans Bölümü, E-posta: levent.guntay@ozyegin.edu.tr - ORCID ID: <https://orcid.org/0000-0002-5532-3101>

\*\* Tam Finans ArGe Departmanı, Analitik Pazarlama ve Krediler Müdürü, E-posta: MehmetAktuna@tamfinans.com.tr - ORCID ID: <https://orcid.org/0000-0003-0700-1578>

Makale Gönderim: 18.01.2021 Makale Kabul: 09.07.2021 DOI: <http://dx.doi.org/10.46520/bddkdergisi.986652>

## 1. Giriş

Factoring, işletmelere likidite sağlayan finansman tekniklerinden biridir. İşletmeler mal ya da hizmet sağladıkları ticari aktiviteler sonrasında iş yaptıkları kurumdan alacaklarını "factoring şirketi"ne devreder ve karşılığında nakit finansman sağlarlar. Alacaklar çoğunlukla vadeli çek şeklinde olduğundan factoring işlemlerinin önemli bir kısmı şirketlerin elindeki vadeli çeklere factoring şirketi tarafından sağlanan nakit finansman şeklindedir. Global ve ulusal ölçekte finansal krizlerin sıklıkla yaşandığı son 20 sene içinde factoring hizmetlerinin önemi artmış ve Türkiye Finansal Kurumlar Birliği verilerine göre 2019'da dünya çapında factoring işlemleri 3 trilyon dolara ulaşmıştır. Özellikle Türkiye'de banka kredisine ulaşmakta zorluk çeken ve tahsilatları hızlandırmak isteyen küçük ve orta ölçekli firmalar factoring hizmetinden önemli ölçüde faydalanmaktadır.

Factoring hizmeti özünde ticarete verilen bir kredi olduğu için hem kanuni zorunluluk hem de risk değerlendirmesi gereğiyle ticaretin doğruluğu kontrol ve teyit edilmelidir. İşlem sayısı arttıkça tüm işlemler için kontrollerin yapılması pratik olarak zor ve maliyetli olduğu gibi, işlem sürecinde insana bağımlılık hata olasılığı yaratmaktadır. Şirket tarafından çek işlemleri sırasında ya da sonrasında oluşan, kolaylıkla öngörülemeyen ve modellenmesi zor bütün olaylar aykırı gözlem olarak nitelendirilmektedir. Aykırı gözlemler bazen önemli risklere işaret edip (örneğin, çek işlemlerinde sahtecilik) bazen de kolayca açıklanabildikleri gibi (örneğin, veri giriş hataları) bazı durumlarda da şirket için olumlu sinyaller taşıyabilirler. (örneğin, müşteri temsilcisi performans artışları). Bu araştırma ile factoring işlemlerinde aykırı değer tespiti kullanılarak krediler, iç denetim, satış ve operasyon birimleri için beklentilerden farklı bir durum oluştuğunda erken uyarı mekanizmaları kurabilmek amaçlanmaktadır.

Factoring işlemlerinde aykırı olaylar için gözetimli bir model geliştirmek güçtür. Farklı aykırılıkların kendi içlerinde karmaşık sebepleri ve dinamikleri olabileceği için gözetimli bir model kurmak amacıyla bu gözlemleri işaretlemek oldukça güçtür. Örneğin, müşterinin factoring hizmeti almadan önce verdiği ticari bilgileri detaylı istihbarat raporu almadan teyit etmek mümkün olmayabilir. Buna ek olarak, aykırı gözlemler çok farklı safha ve birimlerde gözlemlenmektedir. Bu aykırılıklar, çek işlemi, çeki yazan keşideci, çeki tahsil etmek isteyen müşteri, factoring işlemi yürüten müşteri temsilcisi bazında olabildiği gibi işlemlerin gerçekleştiği şube, sektör, zaman periyodu ya da şehir bazında da gerçekleşebilir. Ayrıca aykırı gözlem net şekilde tanımlansa bile Kredi Kayıt Bürosu'ndan elde edilen Çek ve Risk raporları ile birlikte onlarca bağımsız değişkeni gözetimli bir modele sokmak imkansızdır.

Çalışmada faktoring işlemleri için gözetimsiz model oluşturmanın güçlükleri senaryo-bazlı bir metodoloji ile aşılmıştır. İzlenen yenilikçi yöntem ile faktoring alanında aykırı gözlemleri tespit edebilecek risk senaryoları belirlenmiştir. Her risk senaryosu, aykırılık ile ilgili sınırlı sayıda değişkeni veri setinden seçer ve ön işleme sürecinden geçirip aykırılık analizine dahil eder. Bu metodolojinin güçlü yanı, faktoring hakkında derin alan bilgisine sahip olan uzmanların tecrübe ve gözlemleriyle aykırılık analizini senaryolarla şekillendirmesidir. Ayrıca, analizde hiçbir bağımlı sonuç değişkeni ve model yapısı tanımlanmaz ve gözetimsiz analizin esnekliği kullanılarak aykırı değerler ortaya çıkarılır. Metodolojinin güçsüz yanı ise yine gözetimsiz analizin temel bir özelliğinden kaynaklanmaktadır. Gözlemler model oluşturulurken işaretlenmediği için modelin değerlendirmesini yapmak gözetimli analize göre daha güçtür. En nihayetinde, gözetimsiz modelin esas amacı, gözetimli model kurmadan veri setindeki risk dinamikleri hakkında bilgi ve fikir sahibi olmaktır.

Çalışmada önerilen model bir Türk faktoring şirketi olan Tam Finans (Şirket) tarafından sağlanan ve 2018-2020 yılları arasını kapsayan çek veritabanı üzerinde uygulanmaktadır. Şirketin ArGe Departmanı müdür ve koordinatörlerinin tecrübelerine dayanılarak belirlenen yedi risk senaryosu ile üç farklı uzaklık ölçütü hesaplanmış ve temel bileşenler analizi kullanılarak her gözlem için tek ve ortak bir aykırılık endeksi elde edilmiştir. Endeksin 95 persentil eşik değerleri aykırı gözlemleri tespit etmek için kullanılmıştır. Şirket veritabanındaki sorunlu gözlemler faktoring uzmanları tarafından "Sorunlu/Sorunsuz" şeklinde işaretlendikten sonra aykırılık analizinin sorunlu gözlemleri yüksek doğruluk oranı ile tespit ettiği gösterilmiştir. Ayrıca, model tip 1 ve tip 2 hata oranları ve maliyetlerini de gözetilerek şirket veri tabanı üzerinde kalibre edilmiş ve optimal eşik seviyesi %12 olarak bulunmuştur.

Özetle bu çalışma literatüre iki temel katkıda bulunmaktadır. İlk katkısı çok değişkenli veritabanlarında gözetimsiz erken uyarı ve denetim sistemi kurmak istendiğinde alan bilgisine dayalı senaryoların oluşturulması ve kullanılmasını göstermektir. İlave olarak çalışma ile Türk finansal verisi kullanılarak bilinen ilk aykırı değer tespit analizi gerçekleştirilmiştir.

Makalenin geri kalanı şu şekilde düzenlenmiştir. Bölüm 2 faktoring işlemini anlatmakta ve faktoring sektörünün Türkiye'deki ekonomik önemini tartışmaktadır. Bölüm 3 aykırılık literatürünü özetlerken Bölüm 4 çalışmada yer alan aykırılık tespiti istatistiklerini tanımlamaktadır. Bölüm 5 çalışmada kullanılan faktoring veritabanının oluşturulmasını anlatmakta iken Bölüm 6 aykırılık senaryolarını tanımlamaktadır. Bölüm 7'de senaryo bazında aykırılık analizi sonuçları sunulmaktadır. Bölüm 8'de

modelin şirkette uygulanması ve eşik seviyesinin kalibrasyonu anlatılmakta, Bölüm 9 ise makalenin sonuçlarını değerlendirmektedir.

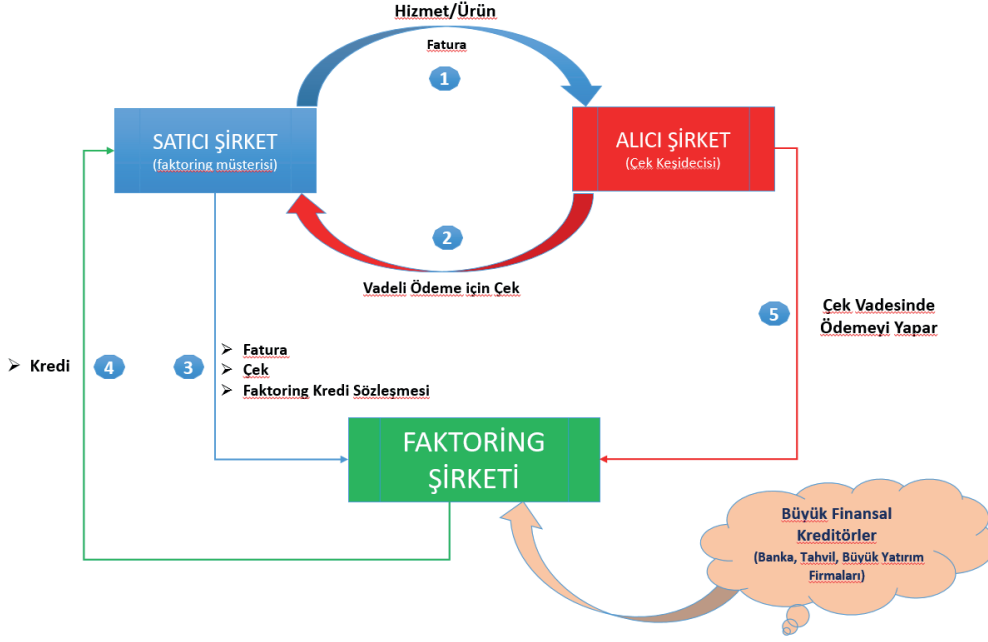
## 2. Faktoring Finansmanı ve Sektörün Ekonomik Önemi

### 2.1. Faktoring İşlemi

Şekil 1 örnek bir faktoring işleminin detaylarını kronolojik sırasıyla numaralandırarak vermektedir. Hizmet ve ürünü alan (alıcı) ve satan (satıcı) arasında gerçekleşen faktoring işlemleri şunlardır.

1. Satıcı firma faturalandırma ile birlikte alıcıya hizmet ya da ürün teslimini yapar.
2. Alıcı firma (Keşideci) çek yazarak vadeli ödeme yapar.
3. Satıcı firma Faktoring şirketine Müşteri olarak başvurur ve onay ister. Faktoring işlemi için öncelikle ticari alışverişi belgeleyen fatura ve diğer belgeleri sunar.
4. Faktoring şirketi çeki yazan Keşideci ve çeki getiren Müşteri hakkında bilgi toplar. Faktoring işleminin onay statüsünü (Kabul/Red) belirler. Kabul durumunda bir alacak iskonto oranı ile Müşteri'ye geri döner. Onay gerçekleşir ve Müşteri Faktoring işlemini gerçekleştirmek isterse alacak hakkını Faktoring şirketine devreder. Faktoring şirketi Müşteri'ye nakit ödeme yaparak kredi vermiş olur. Şirket faktoring işlemleri için finansmanı büyük finansal kreditorlerden elde eder.
5. Çekin vadesi geldiğinde Keşideci Faktoring şirketine ödeme yapar ya da ödeme yapamayıp temerrüte düşer.

## Şekil 1. Çek Alacakları için Faktoring İşleminin Tanımlanması

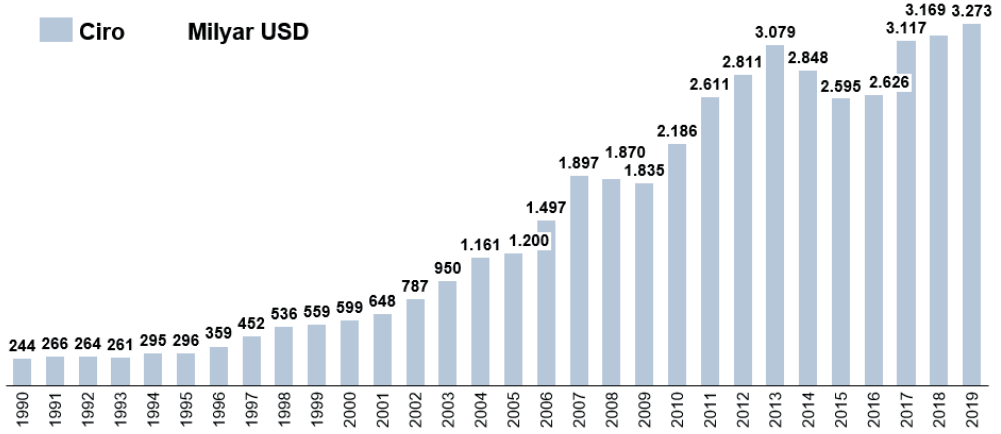


## 2.2. Türkiye’de Faktoring Sektörü

Factoring finansman modelinin dünyadaki ve Türkiye’deki uygulamasına bakıldığında, Türkiye’deki vadeli çek sisteminden kaynaklanan bir fark olduğu görülmektedir. Çek dünyada genellikle vadeye bağlı olmadan anında nakte çevirilebilir bir ödeme aracı iken, Türkiye’de yalnızca vade tarihinde nakde dönüştürülebilir. Bu sebeple, dünyada faktoring finansmanı, çoğunlukla çek dışındaki faturalı vadeli alacakların iskonto edilmesini kapsar. Türkiye’deki faktoring işlemleri ise çoğunlukla fatura ile birlikte ödeme tarihini de içeren çekler aracılığıyla yapılmaktadır. Uygulamalardaki farklılıklara rağmen faktoring, hem dünyada hem de Türkiye’de nakit akışını yönetmek adına özellikle küçük ve orta büyüklükte işletmeler için önemli bir finansman modelidir.

Şekil 2 dünyada faktoring sektörünün gelişimini göstermektedir. Dünyada faktoring sektörü 2000’li yıllarda çok hızlı büyüme gösterdikten sonra 2013 sonrasında büyüme hızı azalmıştır. 2019 yılı itibariyle global faktoring işlem hacmi 3 trilyon USD üzerindedir.


## Şekil 2. Dünyada faktoring sektörü



Kaynak: Finansal Kurumlar Birliği, [www.fkb.org.tr](http://www.fkb.org.tr)

Şekil 3'te görüleceği üzere Türk faktoring sektörü global trende paralel bir gelişme izlemiştir. 2000'li yıllarda hızla büyüyen sektör 2010 yılında 50 milyar USD ciro büyüklüğüne ulaştıktan sonra Türk lirasında 2015'ten sonra hızlanan devalüasyon sebebiyle 2019'da 24 milyar USD seviyesine düşmüştür.

## Şekil 3. Türkiye'de faktoring sektörü




Kaynak: Finansal Kurumlar Birliği, [www.fkb.org.tr](http://www.fkb.org.tr)

Finansal Kurumlar Birliği verilerine göre Eylül 2020 tarihi itibarıyla Türkiye'de 12'si banka iştiraki olmak üzere 56 farklı faktoring şirketi faaliyet göstermektedir. Sektö-

rün toplam aktif büyüklüğü 40,8 milyar TL'ye ulaşmış ve toplam net kârı 789 milyon TL, özkaynak kârlılığı ise %2,8 olarak gerçekleşmiştir.

Şekil 4'te görüleceği üzere sektörün 2020'nin 3. çeyreğindeki toplam takipteki alacak (NPL) oranı %5,4'tür ve son 10 sene boyunca NPL oranı %5 civarında dalgalanmıştır.



Kaynak: Finansal Kurumlar Birliği, [www.fkb.org.tr](http://www.fkb.org.tr)

### 3. Aykırılık Tespiti Literatürü

Aykırılık tespitinin amacı oluşan aykırı olayları işaretlemekten, sınıflandırmadan ve gözetimli bir istatistiksel ya da ekonometrik model kullanmadan, gözetimsiz yöntemlerle bulup erken uyarı veren sağlam ölçütler elde etmektir. Aykırı gözlemler bankacılık ve finansal piyasa işlemlerinde sıklıkla sahtecilik ya da manipülasyon olayları gibi risk teşkil eden durumları gösterebildiği gibi, yatırımcılara kar fırsatı sunan işlemler için olumlu sinyal niteliği de taşıyabilir. (Esen ve Timor, 2019).

Aykırılık tespit modelleri kendi içinde kesitsel aykırılık ve zaman serisi aykırılık yöntemleri olarak ikiye ayrılabilir. Kesitsel aykırılık analizi aynı zaman biriminde gözlemlenen birey, kurum, ya da işlemler içinde aykırı olanları bulmayı amaçlar. Zaman serisi aykırılık analizi ise aynı birey, kurum, ya da nesnenin zaman içinde değişen davranışlarını önceki davranışları ile kıyaslayarak aykırılık sonucuna varır. Örneğin vadesi diğer çeklerden çok daha uzun olan 5 yıl vadeli bir çek kesitsel analizle aykırı olarak nitelendirilirken, herhangi bir çekin dört farklı tarihte faktoring işlemi için aynı faktoring kurumunda işleme alınması zaman serisi analizi ile aykırı olarak değerlendirilir. Bu çalışmada sunulan sonuçlar kesitsel aykırılık analizi ile elde edilmiştir.

Kesitsel aykırılık analizi de kendi içinde farklı kategorilere ayrılır. Aykırılık literatürü

Mahalanobis (1936) uzaklığı ile başlamış ve “Merkeze (ortalamaya) uzaklığa dayalı” aykırılık yöntemleri sıklıkla kullanılmıştır. Mahalanobis uzaklığını sağlamlaştırmaya çalışan temel çalışmalar Gnanadesikan ve Kettenring (1972), Devlin vd. (1975,1981), Rousseeuw (1985), Rousseeuw ve Driessen (1999), Maronna ve Zamar (2002), Rousseeuw ve Leroy (2005) olmuştur. Değişken ve gözlem sayısının çok fazla olduğu büyük veritabanlarında kullanılması gereken uzaklığa dayalı yöntemleri Knorr ve Ng (1998) tartışmıştır.

“Komşuluk bazlı” aykırılık yöntemleri bir gözlemin merkezden değil komşularından uzaklığına bakarak aykırılık istatistikleri oluşturur. En yakın k-komşu analizini kullanan Ramaswamy vd. (2000), Chawla ve Gionis (2013) ve Çetiner vd. (2020) ile lokal aykırılık faktörünü öneren Breunig vd. (2000) bu gruptaki çalışmalara örnektir. Lokal dağılımları kullanan Tang and He (2017) komşuluk bazlı aykırılık yöntemlerinin parametrik olarak nasıl geliştirilebileceğini göstermektedir.

“Açı bazlı” aykırılık yöntemleri seyrek (sparse) veri tabanları için önerilmekte ve bir gözlemin diğer tüm noktalarla olan açısının varyansını kullanmaktadır. Kriegel vd. (2008)’de gösterildiği üzere düşük açı varyansı aykırı gözlemleri keskin şekilde tespit edebilmektedir.

“Kümelenme bazlı” aykırılık yöntemlerinin sonuçların sınıflandırılmamış ve isimlendirilmemiş olduğu büyük veri tabanlarında çok farklı tipte güvenlik ihlallerini ortaya çıkarabildiği Eskin vd. (2001) tarafından gösterilmiştir. Jiang ve An (2008) ve Moh’d Belal vd. (2010) bulanık kümelenme ve Campello vd. (2015) ise hiyerarşik kümelenme ile aykırılık analizini incelemiştir. Duan vd. (2009) kümelenme bazlı aykırılık yöntemlerini detaylıca karşılaştırmaktadır.

“İlişki kuralı bazlı” yöntemlerin kredi kartı sahtekarlığı tespitinde fazla sayıda kategorik ve sürekli değişken içeren büyük veri ile verimli şekilde çalıştığı Sanchez vd. (2009)’da gözlenmiştir.

Cao vd. (2018) ise “Bilgi ağları” yaklaşımını kullanmış ve tek başına incelendiğinde aykırı gözükmeyen davranışların ortak davranış ilişkilerinin ağ yapısını incelendikten sonra sahtecilik tespiti için bilgi sağladığını bulmuştur.

Zaman serisi aykırılık analizi kategorisinde finansal literatürde sıklıkla rastlanan ve ortalama modelleyen “Otoregresif entegre hareketli ortalamalar”<sup>1</sup> ve varyasyonu modelleyen “Genel otoregresif koşullu değişen varyans”<sup>2</sup> modelleri ön plana çıkar.

1 Autoregressive integrated moving average (ARIMA)

2 Generalized autoregressive conditional heteroskedastic (GARCH)



(örneğin Ane vd., 2008). Weekley vd. (2010) finansal veriye oldukça benzeyen atmosferik zaman serileri üzerinde kümelenme bazlı aykırılık analizi sonuçları geliştirmiştir. Müşterilerin kredi kartı harcamalarındaki aykırı değişimleri "Yarı Gizli Markov" modeli ile inceleyen Prakash vd. (2012) başarılı bir sahtecilik tespiti modeli geliştirmiştir. Öte yandan "Grafik bazlı" aykırılık yöntemleri Rahmani vd. (2014) tarafından firma karlılığındaki aykırı değişimleri bulmak için başarıyla uygulanmıştır.

#### 4. Aykırılık Tespit Ölçütleri

Çalışmada aykırılık tespiti için "uzaklığa dayalı" kesitsel aykırılık yöntemi olan Mahalanobis uzaklığı ve onun daha sağlam versiyonları olan Minimum Kovaryans Uzaklığı (MCD) ve Ortogonalize Gnanadesikan-Kettenring Uzaklığı (OGK) kullanılmaktadır. Mahalanobis ve türevleri olan bu üç ölçütün seçilme nedeni kesitsel işletme ve ekonomideki aykırılık analizi çalışmalarında sıklıkla kullanılmalarıdır. Örneğin bu ölçütler finansal dolandırıcılık tespiti ve iflas tahminlemesi (Cho vd., 2010; Pozollo vd., 2014; Carminati vd., 2015), kredi riski hesaplanması (Pompella ve Dicario, 2017; Karminsky ve Khromova, 2018) ve müşteri memnuniyeti ölçümü (Alpu, 2019) alanlarında başarıyla kullanılmıştır.

Öklit, Minkowski ve Silhouette gibi uzaklık ölçütleri farklı değişkenler arasındaki korelasyondan bağımsızdır. Bu korelasyon yapısı aykırılık analizinde önemli olduğundan bu ölçütler çalışmada kullanılmamıştır. Aşağıda çalışmada kullanılan üç ölçütün hesaplanma detayları anlatılmaktadır.

##### 4.1. Klasik Mahalanobis Uzaklığı

Mahalanobis uzaklığı, çok boyutlu bir  $x$  noktası ile bir  $D$  dağılımı arasındaki mesafenin bir ölçüsüdür. Başka bir deyişle, tek değişkeni temsil eden tek boyutlu  $x$  noktasının  $D$ 'nin ortalamasından kaç standart sapma uzaklaştığını ölçme fikrinin (z-skoru) çok boyutlu genellemesidir.  $x$ ,  $D$ 'nin tam ortalamasındaysa bu mesafe sıfırdır ve  $x$  ortalamadan uzaklaştıkça bu mesafe büyür. Mahalanobis mesafesi birimsiz ve ölçekten bağımsızdır ve veri setindeki değişkenlerin aralarındaki korelasyonu dikkate alır.

Öncelikle  $x_1, \dots, x_n \in R^p$  nin  $p$  boyutlu ( $p$  farklı değişken) ve  $n$  gözlemden oluşan bir veri setini temsil ettiğini kabul edelim. Genel notasyon olarak, veritabanı  $X = [x_{ij}] n \times p$  matrisi olup, satırları gözlemleri  $x_i^T (i = 1, \dots, n)$  ve sütunları da değişkenleri  $X_j (j = 1, \dots, p)$  oluştursun.

Bu veriseti için  $p$  boyutlu  $x_i$  noktasının  $\hat{\mu}$  örneklem ortalaması ve  $\hat{\Sigma}$  örneklem kovaryans matrisi 1 ve 2 numaralı denklemlerde tanımlanmıştır.

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i \quad (1)$$

$$\hat{\Sigma} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \hat{\mu})(x_i - \hat{\mu})^T \quad (2)$$

$x_i$  noktasının Mahalanobis uzaklığı,  $MD(x_i)$  aşağıdaki şekilde tanımlanır.

$$MD(x_i) = \sqrt{(x_i - \hat{\mu})^T \hat{\Sigma}^{-1} (x_i - \hat{\mu})} \quad (3)$$


$p$  sayıda değişken ile hesaplanan Mahalanobis uzaklığının karesi ki-kare dağılım göstereceğinden uzaklığın  $\alpha$  persentil değeri için aykırı gözlemleri 1 olarak işaretleyen indikatör fonksiyonu aşağıda tanımlanmıştır.

$$I(x_i) = I(MD(x_i)^2 \leq \chi_{p-1}^2(\alpha)) \quad (4)$$

## 4.2. Minimum Kovaryans Uzaklığı (MCD)

Minimum kovaryans uzaklığı Rousseeuw (1985)'da önerildiği üzere Mahalanobis uzaklığını sağlamlaştıran bir yöntemdir. Yöntemin temel amacı ortalamayı ve kovaryans matrisini aykırı değerleri çıkartarak daha sağlam şekilde hesaplamaktır.

### Şekil 5. Klasik Mahalanobis ve Minimum Kovaryans Uzaklığı (MCD) Karşılaştırılması



Not: Kırmızı (Mavi) şekil klasik Mahalanobis (MCD) uzaklığının 97.5 persentil eliptik sınırını göstermektedir.

Şekil 5'te iki değişken için Mahalanobis uzaklığı ve MCD ile 97.5 persentil eliptik aykırı değer sınırları çizilmiştir. Mahalanobis'e göre grafiğin sağ altındaki üç nokta kırmızı elipsin dışında kalmış ve aykırı değer olarak nitelendirilmiştir.

Öte yandan mavi elips aykırı değerlerin ve eliptik sınırın MCD yöntemi ile hesaplandığı durumu göstermektedir. Bu elipsin çiziminde Mahalanobis aykırı değerleri ortalama ve kovaryans hesabında kullanılmamaktadır. Sonuçta mavi elips daha dar ve kompakt sınırlar çizmekte ve kırmızı elips içerisinde kalan 5 ilave nokta daha aykırı değer olarak işaretlenmiştir.

MCD uzaklığını hesaplamak için önce Mahalanobis uzaklığını saptanır.

$$d(x_i) = \sqrt{(x_i - \hat{\mu})^T \hat{\Sigma}^{-1} (x_i - \hat{\mu})} \quad (5)$$

W ile gösterilen ağırlık indikatör fonksiyonu herhangi bir x noktası Mahalanobis uzaklığına göre aykırı değer olması durumunda 1 değerini almaktadır. Uzaklığın karesi  $\chi^2$  dağılımına uyduğundan, p değişkenli bir veri tabanında  $\alpha$  persentil için W ağırlığı şöyle hesaplanmaktadır.

$$W(d_i^2) = I(d(x_i)^2 \leq \chi_{p-1}^2(\alpha)) \quad (6)$$

Bu ağırlık fonksiyonu ile  $\alpha$  persentil dışında olan aykırı noktalar dahil edilmediğinde ortalama, kovaryans matrisi ve MCD uzaklığı şöyle hesaplanır.

$$\hat{\mu}_{MCD} = \frac{\sum_{i=1}^N W(d_i^2) x_i}{\sum_{i=1}^N W(d_i^2)} \quad (7)$$

$$\hat{\Sigma}_{MCD} = \frac{\sum_{i=1}^N W(d_i^2) (x_i - \hat{\mu}_{MCD})(x_i - \hat{\mu}_{MCD})^T}{\sum_{i=1}^N W(d_i^2)} \quad (8)$$

$$MCD(x_i) = \sqrt{(x_i - \hat{\mu}_{MCD})^T \hat{\Sigma}_{MCD}^{-1} (x_i - \hat{\mu}_{MCD})} \quad (9)$$

### 4.3. Ortogonalize Gnanadesikan-Kettenring (OGK) Uzaklığı

MCD uzaklığının hesaplanması çok değişkenli veritabanları için oldukça uzun zaman alabilmektedir. İlk defa Gnanadesikan ve Kettenring (1972) çalışmasında tanımlanan OGK uzaklığı MCD'nin sağlamlık özelliğini muhafaza edip nümerik olarak hızlı hesaplanabilen bir aykırılık metriği sunmaktadır. OGK uzaklığının MCD uzaklığından temel farklılığı W ağırlık fonksiyonunun hesaplanmasındadır.

Maronna ve Zamar (2002) OGK'nin birden fazla iterasyona sokularak hesaplanmasını gösterir. İlk iterasyonda  $d_1, \dots, d_n$  değerleri Mahalanobis uzaklığı ile hesaplandıktan sonra  $d_0$  eşik değerine göre W indikatör ağırlık fonksiyonu bulunur.

$$d_0 = \frac{\chi_p^2(\beta) \text{msd}(d_1, \dots, d_n)}{\chi_p^2(0.5)} \quad (10)$$

$$W(d) = I(d \leq d_0) \quad (11)$$

Med(.), medyan değeri göstermektedir,  $\chi_p^2(\beta)$ ,  $\beta$  persentil ve p serbestlik derecesi için ki-kare istatistiđi kritik değeri, I(.) ise sıfır ve bir değeri alan indikatör fonksiyondur.

Bu ağırlık fonksiyonuyla 7, 8 ve 9 numaralı denklemler kullanılarak birinci iterasyon ve  $\beta$  persentil için  $OGK_1(\beta)$  istatistiđi hesaplanır. İki den fazla iterasyonun istatistiđinin değeri fazlaca değıştirmedięi gözlenmiştir. Çalışmada  $OGK_1(0.95)$  istatistiđi kullanılmakta ve testlerde kısaca OGK olarak bahsedilmektedir.

Çalışmada Mahalanobis, MCD ve OGK uzaklıkları tanımlanırken sürekli değışkenlere ek olarak kategorik değışkenler de kullanılacaktır. Bu amaçla, bir kategorik değışkenin her farklı değeri için ayrı bir kukla değışken tanımlanarak uzaklık hesaplanmasında kullanılacaktır.

## 5. Çalışmada Kullanılan Veritabanı

Öncelikle şirket tarafından 2018 ile 2020 arasındaki faktoring işlemlerinden elde edilen Çek, Müşteri, Keşideci ve Müşteri temsilcisi ile ilgili bilgiler derlenerek faktoring veritabanı oluşturulmuştur. Sonrasında Kredi Kayıt Bürosu'ndan (KKB) keşideciler ve müşteriler için Çek Raporu ve Risk Raporu elde edilmiş ve bu veriler faktoring veritabanı ile birleştirilmiştir.

KKB çek raporu kredi kayıt bürosu tarafından sunulan detaylı çek kayıtlarını içermekte ve karşılıksız çeklere ilişkin dökümü de verebilmektedir. Raporla, keşidecinin kestiđi, ödedięi ya da karşılıksız kalan çek sayıları ve miktarları ve bu istatistiklerin son 1, 3 ya da 12 ay için dökümleri ile birlikte sağlanmaktadır. KKB risk raporu ise geçmiş ve güncel bireysel ve ticari işlemler ve ödemeler hakkında bilgileri içermekte ve bir kredi risk skoru atamaktadır. Ek 1 çek ve risk raporları ile KKB'den elde edilebilecek değışken listesini vermektedir.

Çalışmada kullanılan ve faktoring, çek ve risk raporları ile ilgili verilerin birleştirilmesiyle oluşturulmuş veritabanı Ocak 2018 ile Haziran 2020 arasında 38.500 müşteri ve 622 müşteri temsilcisi için 285.000 çek başvurusu ve 103.000 adet krediye dönüşen çek işlemini içermektedir.

Çalışmada kullanılan 7 aylık tespiti senaryosunu şirketin ArGe bölümünde görevli "Analitik Pazarlama ve Krediler Müdürü" ve "Analitik Pazarlama ve Krediler Koordinatörü" birlikte oluşturmuşlardır. Ayrıca tüm gözlemleri "Sorunlu" ve "Sorunsuz" olarak işaretlemişlerdir.

## 6. Aykırılık Tespit Senaryolarının Oluşturulması

### 6.1. Aykırılık Tespit İstatistiklerinin Tanımlanması

Bu bölümde çok değişkenli veri setlerinde aykırı değer tespitini destekleyen senaryoların oluşturulması açıklanmakta ve veritabanından örnekler verilmektedir. Önceden tanımlandığı üzere çek işlemleri ile ilgili kolaylıkla öngörülemeyen ve modellenmesi güç olaylar aykırı gözlem olarak nitelendirilmektedir. Aykırı gözlemleri bulabilmek için faktoring veritabanı faktoring uzmanlarının faktoring alanındaki bilgileri ve öngörülerini doğrultusunda incelenmiş ve yedi adet aykırılık senaryosu oluşturulmuştur. Her senaryoda farklı değişken kümeleri ve rasyoları kolaylıkla öngörülemeyen bir risk kurgusu ile bir araya getirilir ve ön işlemden geçirilir.

Senaryo yaklaşımına göre her S senaryosu p adet bağımsız değişken,  $X_i$  içeren X veritabanından bir bağımsız değişken alt kümesi seçilmesi  $\{ \{X_1, X_2, X_3 \dots X_p\} \subset X \}$  ve bunlara transformasyon uygulanması  $\{f_1, f_2, f_3 \dots f_p\}$  ile tanımlanır. Değişkenler bazen aynen kalabildiği gibi, sürekli değişkenler kategorize edilebilir, ya da değişkenlerdeki değişim ya da yüzdesel değişim hesaplanabilir. Ayrıca iki farklı değişkenin farkı ya da rasyosu da oluşturulabilir.

Öncelikle aykırılık analizinde sözkonusu olan M farklı iki sonuçlu olay olduğunu ve bunlardan herhangi birinin oluşmasının aykırılık yarattığını varsayalım.  $I_m$  olay gerçekleşirse 1 değerini alan indikatör değişkeni iken  $I$  ise herhangi bir aykırılığa sahip gözlemi belirten indikatör fonksiyonudur.

$$I(x_i) = \max_{1..M} I_m(x_i) \quad (12)$$

Örneğin  $I_1$  çek sahteciliği,  $I_2$  çekin vadesinde ödenmemesini,  $I_3$  çekle ilgili verilerin veritabanında yanlış olmasını gösterebilir. Bu olaylar gerçekleştiğinde bu değişkenler 1 aksi takdirde 0 değerini alacaklardır. Fakat önceden bahsettiğimiz gibi aykırılık sonuçlarının olay bazında modellenmesi hatta gözlemlenip işaretlenmesi güçtür.

Senaryo bazlı yaklaşımda farklı aykırılık olaylarını içinde barındıran senaryo tanımları yapılır ve bu senaryoların tümünün birlikte aykırı gözlemleri içerdiği varsayılır. Örneğin  $I_1$  olayı yalnızca çek sahtecilik riskini tanımlasa bile  $S_1$ ,  $S_2$  ve  $S_5$  senaryolarının her biri sahtecilik olayını içerebilir. Ayrıca tek bir senaryo da birden fazla olayı içinde barındırabilir. Örneğin,  $S_1$  senaryosu hem veri girişi hatası hem de sahtecilik olayını içerebilir.

Senaryo yaklaşımında  $x_i$  gözlemi ve s senaryosu için aykırı gözlem  $O_s(x_i)$  indikatör fonksiyonu ile tanımlanır. Seçilen ve transforme edilen değişkenler ile hesaplanan

$d$  aykırılık skoru bir  $d_{s,\alpha}$  eşik değerini geçerse  $s$  senaryosuna göre bu gözlem aykırı olarak nitelendirilecektir.  $d_{s,\alpha}$  ise  $d$  uzaklığının  $\alpha$  persentil değeri olarak tanımlanmıştır.

$$O_s(x_i) = \hat{I}(d_s(x_i) > d_{s,\alpha}) \quad (13)$$

$x_i$  gözlemi için tüm senaryolar dikkate alındığında aykırılık tahmini  $\hat{I}(x)$  şöyle olacaktır.

$$\hat{I}(x_i) = \text{maks}_{1..S} O_s(x_i) \quad (14)$$

Görüldüğü gibi aykırılık modelinin amacı senaryoları uygun değişken kümeleri ve değişken transformasyonları ile optimal şekilde seçerek gerçekleşen ve model tarafından tahmin edilen aykırı gözlemlerin arasındaki farkın karesinin toplamının,  $J(X)$ ,  $X$  verisetindeki gözlemler üzerinde minimize etmek şeklinde tanımlanabilir.

$$J(X) = \min_{\{1..S\}} \left\{ \sum_X (I(x_i) - \hat{I}(x_i))^2 \right\} \quad (15)$$

Senaryo bazlı aykırılık analizi çerçevesinde bir istatistik daha üretilebilir. Bir müşteri birden farklı senaryo tarafından aykırı olarak sınıflandırılırsa aykırılık incelemesinde öne çıkacaktır. Bu durumda bir  $x_i$  gözlemi için senaryo indikatör değerlerinin toplandığı bir aykırılık güç skoru,  $P$  tanımlanabilir.

$$P_{\text{Müşteri}}(x_i) = \sum_S O_s(x_i) \quad (16)$$

Tahmin edileceği gibi aykırılık güç skoru,  $P(x_i)$  ve gözlemin aykırı olup olmama ihtimali,  $Pr(I(x_i) = 1)$  arasında kuvvetli bir bağ olacaktır. Model tarafından aykırı gözlem olarak sınıflandırılan her gözlemin birden büyük bir  $P$  skoru olacağından,  $P$  skoru öncelikle ve ivedilikle incelenmesi gereken gözlemleri ayırmakta faydalı olacaktır.

## 6.2. Aykırılık Tespit Senaryolarının Oluşturulması

Factoring aykırılık analizinde kullanılan senaryoların kurguları ve değişken listesi senaryo için değişken listesi ve özet istatistik tabloları ile aşağıda tartışılmaktadır.

### 6.2.1. Senaryo I. Müşteri ve Faiz İlişkisi

Factoring sektöründe faiz oranları çeklerin vade, tutar, ve firma tarafından skorlama ile belirlenen kredi riskinin yanı sıra müşterilerin pazarlık gücüne bağlı olarak da değişir. Özellikle farklı factoring firmaları ve bankalarla çalışan ve krediye rahatlıkla ulaşacak müşterilerin daha düşük faiz oranı ile işlem yapabilmeleri beklenir.

Aykırlık tespiti yapılacak faiz oranı oluşması için müşteri ile önceden işlem yapmış olmak gerektiğinden, bu senaryoda müşteri kümesi önceden işlem yapmış müşteriler olarak belirlenmiştir<sup>3</sup>.

**Tablo 1. Senaryo 1 Değişkenleri İstatistikleri**

Gözlem sayısı =38513	Min	Maks	Med	Ort	St Sap
Çalışılan Faktoring Kurum Sayısı	0	21	2	2.02	1.84
Çalışılan Finansal Kurum Sayısı	0	22	1	2.17	2.51
Factoring Riski / Faktoring Limiti	0	1	0.1	0.16	0.2
Nakdi Risk / Nakdi Limit	0	162388	0.54	41.6	1863.52
Toplam Nakdi Limit	0	184315702	29700	436408	2283016
Bireysel Kredi Notu	0	1900	1037	907.39	524.62

## 6.2.2. Senaryo II. Müşteri Temsilcisi Görev Süresi ve İşlem Sayısı İlişkisi

Bir müşteri temsilcisinin faktoring şirketindeki görev süresine paralel bir işlem performansı göstermesi beklenir. Örneğin şirkette 18 aylık geçmişi bulunan bir temsilcinin benzer geçmişi olan meslektaşlarından üç kat daha fazla çek getirmesi, onaylatması ve kullandırması pozitif bir performans göstergesi olabileceği gibi dolandırıcılık şüphesi de oluşturabilir. Bu durumun hem insan kaynakları hem de risk denetim süreçlerinde incelenmesi gerekmektedir. Aşağıda değişken listesi ve sayısal örneği verilen senaryoda aykırılık analizi müşteri temsilcisi görev süresine göre ay bazında yapılmaktadır ve bu sebeple diğer senaryolardan ayrılmaktadır.

**Tablo 2. Senaryo 2 Değişkenleri İstatistikleri**

Gözlem sayısı =8512	Min	Maks	Med	Ort	St Sap
Müşteri Temsilcisi Görev Süresi	0	97	17	23,32	21,14
İçeri Giren Çek Sayısı	1	583	105	115,56	84,15
Onaylanan Çek Sayısı	0	292	49	55,26	41,58
Kullandırılan Çek Sayısı	0	198	32	36,94	29,24
İçeri Giren Toplam Çek Hacmi (TL)	3000	36626028	3513694	3798221	2712492
Kullandırılan Toplam Çek Hacmi (TL)	0	4065312	636718	720035	557600
Onaylanan Çek / İçeri Giren Çek	0	1	0,48	0,47	0,15
Kullandırılan Çek / Onaylanan Çek	0	1	0,66	0,62	0,2

<sup>3</sup> Senaryo 1’de “Factoring işleminde Müşterinin ödediği faiz” aykırılık skoru hesaplamasına dahil olan bir değişkendir. Fakat, bu değişken Şirket için stratejik veri olduğundan Tablo 1’de değişkenin dağılımı ile ilgili bir istatistik verilmemiştir.

### 6.2.3. Senaryo III. Müşteri Geçmişi ve Limit İlişkisi

Çoğunlukla yeni kurulmuş ve banka kredisi için gerekli finansal performansı sağlayamayan firmalar vadeli alacakları karşılığı faktoring yaparlar. Faktoring faiz oranları görece yüksek olduğundan, banka kredilerine rahatlıkla ulaşabilen firmalar için faktoring birinci tercih değildir. Bu senaryoda, uzun süreli ticari hayatı olan (ticari yaşı büyük) ve banka kredisine ulaşabilen ve banka limitleri olan müşteri firmaların faktoring yapmalarının oluşturduğu aykırılık incelenmektedir.

Bu senaryo kümesini oluşturan kriter müşterinin bankada limiti olması ve daha önceden çek getirmiş olmasıdır.

**Tablo 3. Senaryo 3 Değişkenleri İstatistikleri**

Gözlem sayısı =118231	Min	Maks	Med	Ort	St Sap
Müşteri Geçmişi	0	121	4	6,02	6,74
Bireysel Kredi Notu	0	1900	1069	951,2	529,8
Nakdi Risk / Nakdi Limit	0	254304	0,53	40,7	2105,3
Toplam Nakdi Limit	0	1139227792	26415	639773	6001754

### 6.2.4. Senaryo IV. Müşteri İşlem Sıklığında Değişme

Bu senaryoda müşterilerin çek işlemi için başvurma sıklıklarının (çek getirme adeti) son dönemde artış gösterip göstermediği incelenmiştir. Son dönemde alışkanlıklarından önemli ölçüde farklı davranan bir müşterinin yakından incelenmesi gerekmektedir. Ancak değişim müşterilerin büyük çoğunluğunda gözlemleniyorsa gözlem aykırı değer olarak kabul edilmez. Bu sebeple, bu senaryoda müşterilerin işlem sıklıklarındaki değişim diğer müşterilerdeki değişim ile kıyaslanarak aykırılığa karar verilecektir. Modeldeki son üç rasyoda bölen olarak çok sayıda sıfırın varlığı sebebiyle, rasyoyu doğru şekilde tanımlamak için pay ve paydadaki değerlere 1 sayısı eklenmiştir. Ayrıca bu üç rasyodaki aşırı çarpıklık sebebiyle rasyoların doğal logaritması alınmıştır.

Bu senaryoda müşteri kümesi, verinin oluşturulduğu tarihten sonraki 30 gün içerisinde çek getirmiş müşterilerdir.



**Tablo 4. Senaryo 4 Değişkenleri İstatistikleri**

Gözlem sayısı =8397	Min	Maks	Med	Ort	St Sap
Müşteri Geçmiş	3	98	19	25,17	19,52
İçeri Giren Çek Adedi Aylık Ortalama	0,67	19,3	1,89	2,28	1,40
Çek Kullanım Oranı	0	1	0,38	0,40	0,24
İçeri Giren Çek Sıklığı	0,03	3,33	0,59	0,63	0,34
Çek Kullanım Sıklığı	0	1	0,50	0,51	0,26
Çek Kullanım Oranı Değişimi	-1	1	-0,10	-0,06	0,34
$\log\left(\frac{1 + 30 \text{ günlük Çek Kullanım Adedi}}{1 + \text{Çek Kullanım Adedi Aylık Ortalama}}\right)$	-1,73	2,28	0	0,02	0,46
$\log\left(\frac{1 + 30 \text{ günlük Çek Kullanım Tutarı}}{1 + \text{Çek Kullanım Tutarı Aylık Ortalama}}\right)$	-6,64	5,08	-0,60	-1,50	1,87
$\log\left(\frac{1 + 30 \text{ günlük İçeri Giren Çek Adedi}}{1 + \text{İçeri Giren Çek Adedi Aylık Ortalama}}\right)$	-2,40	1,61	-0,34	-0,43	0,52

### 6.2.5. Senaryo V. Müşterinin Uzaktan İşlem Alışkanlığı

Dijitalleşme ile müşteriler faktoring işlem başvurularını uzaktan gerçekleştirebilmektedir. Genelden şubelere uzak müşteriler bu yöntemi tercih etmektedir. Bu senaryoda müşterilerin uzaktan çek işlemi yapma sıklığı gözlemlenmekte ve son dönemdeki davranışlarındaki değişim aykırılık açısından incelenmektedir.

Bu senaryoda müşteri kümesi daha önceden çevrimiçi ya da mobil kanalla işlem yapmış müşteriler ile sınırlandırılmıştır.

**Tablo 5. Senaryo 5 Değişkenleri İstatistikleri**

Gözlem sayısı = 891	Min	Maks	Med	Ort	St Sap
Toplam Çek Kullanım	1	147	9	14,67	16,85
Uzaktan Çek Kullanım Oranı	0,01	1	0,13	0,22	0,23
30 günlük Uzaktan Çek Kullanım Oranı	0	1	0,33	0,45	0,47

## 6.2.6. Senaryo VI. Çek Kurgusu

Türkiye’de çekin KOBİ’ler için önemi, ticari ödemelerde para yerine kullanılabilirliği. Bir firma aldığı çeki başka bir firma ile olan ticaretinin bedelini ödemek için kullanabilir ve böylece çekler firmadan firmaya dolaşır faktoring şirketine birden fazla kez farklı müşterilerden ve farklı şubelerden gelebilir. Bu durum bir sahtekarlık girişimi olabileceği gibi ticari ilişki ağları için de bilgi verir.

Bu senaryoda, birden fazla kez faktoring işlemi için gelen çeklere odaklanılmış ve çekin kaç farklı zamanda, kaç farklı müşteri, şube ya da müşteri temsilcisi aracılığı ile geldiği bilgisi kullanılmıştır.

**Tablo 6. Senaryo 6 Değişkenleri İstatistikleri**

Gözlem sayısı = 131802	Min	Maks	Med	Ort	St Sap
Çekin Geliş Sayısı	2	31	2	2,25	0,65
Çekin Geldiği Şube Sayısı	1	4	1	1,03	0,18
Çekin Geldiği Müşteri Temsilcisi Sayısı	1	4	1	1,07	0,26
Çeki Getiren Farklı Müşteri Sayısı	1	4	1	1,10	0,30

## 6.2.7. Senaryo VII. Müşteri Geçmişi ve İşlem Frekansı

Factoring müşterilerinin ağırlıklı olarak yeni kurulmuş ve ticari ve kredi geçmişleri kısa firmalar olduğu Senaryo 3’te işlenmişti. Ticari hayata yeni atılmış firmaların çok fazla sayıda çek ve büyük tutarlar ile faktoring başvurusu yapması da aykırı bir davranış olarak şüphe uyandırır. Ancak bu adet ve tutarların normalinin ne olduğu müşteri kümesine göre şekillenecektir. Bu senaryo müşterilerin geçmişleri ve getirdikleri çek adet ve tutarları ile oluşturulmuştur.

Bu senaryo yeni kurulmuş 12 aydan yaşı küçük firmaların çek getirme alışkanlıklarındaki aykırılıklara bakmaktadır.

**Tablo 7. Senaryo 7 Değişkenleri İstatistikleri**

Gözlem sayısı=4658	Min	Maks	Med	Ort	St Sap
Müşteri Geçmişi	0	12	9	8,29	2,94
Müşterinin Getirdiği Çek Sayısı	1	148	3	5,58	8,61
Müşterinin Getirdiği Çek Tutarı	1000	11144049	96000	210630	383567

## 7. Senaryo Bazında Aykırılık Analizi Sonuçları

Bu bölüm senaryolara dayalı gözetimsiz aykırılık tespit modelinin sonuçlarını sunar. Altıncı bölümde tanımlanmış yedi senaryo için üç adet aykırılık istatistiği (Mahalanobis, MCD, OGK) her gözlem için tek tek hesaplanmakta, aykırılık endeksi oluşturulmakta ve bunların aralarındaki ilişki incelenmektedir. Aykırılık istatistiklerinin hesaplanması için R programlama dili ve "Robustbase" kütüphanesi kullanılmıştır. Maronna vd. (2019) R ile aykırılık istatistiklerin hesaplanması konusunda detaylı bilgi vermektedir.

Bu amaçla Tablo 8'in ilk üç sütunu her senaryo için üç istatistik arasındaki ikili Pearson korelasyonlarını göstermektedir. Gözlemlendiği üzere çoğu senaryoda üç istatistik arasında %80'in üzerinde yüksek korelasyon mevcut iken Senaryo 4 ve 5'deki bazı korelasyonlarda bu oran %30-%40 civarına düşebilmektedir. Bu yüksek korelasyon değerleri üç aykırılık istatistiğinin aykırı gözlemler için oldukça benzer sıralamalar yaptığını gösterir. Ama korelasyon değerleri %100'e yakın olmadığı sürece farklı istatistikler gözlemlerin aykırılık derecesi için oldukça farklı sonuçlar üretebilirler.

**Tablo 8. Senaryolardan Elde Edilen Aykırı Değer İstatistiklerinin Pearson Korelasyonları**

SENARYO	MAH-MCD	MAH-OGK	MCD-OGK	MAH-AI	MCD-AI	OGK-AI
1	0,75	0,78	0,80	0,91	0,92	0,93
2	0,70	0,76	0,93	0,87	0,97	0,95
3	0,83	0,85	0,85	0,94	0,94	0,95
4	0,41	0,61	0,96	0,73	0,92	0,98
5	0,33	0,87	0,27	0,94	0,54	0,93
6	0,97	0,94	0,98	0,98	0,99	0,99
7	0,88	0,77	0,96	0,92	0,99	0,96

Pearson korelasyon katsayısı iki değişkendeki ekstrem değerlere fazlasıyla hassastır. Bu sebeple ekstrem değerlerden etkilenmeyen Spearman sıralama korelasyonu sonuçları Tablo 9'un ilk üç sütununda sunulmuştur. Spearman metodu ile de üç aykırılık ölçütü arasında %80 civarı yüksek korelasyon gözlemlenmiştir. Senaryo 5'te korelasyonlar yükselmiş olmakla beraber %50 seviyesine çıkmıştır.

**Tablo 9. Senaryolardan Elde Edilen Aykırı Değer İstatistiklerinin Spearman Korelasyonları**

SENARYO	MAH-MCD	MAH-OGK	MCD-OGK	MAH-AI	MCD-AI	OGK-AI
1	0,85	0,81	0,73	0,93	0,94	0,86
2	0,75	0,81	0,88	0,93	0,94	0,90
3	0,88	0,86	0,92	0,96	0,95	0,95
4	0,86	0,86	0,88	0,94	0,94	0,96
5	0,50	0,83	0,39	0,89	0,73	0,83
6	0,74	0,76	0,97	0,91	0,93	0,95
7	0,63	0,71	0,90	0,93	0,84	0,89

Korelasyon analizi farklı aykırılık istatistikleri arasında mükemmel olmayan bir ilişkiyi göstermektedir. Bu amaçla üç istatistikten tek ortak bir aykırılık endeksi oluşturmak için Temel Bileşenler Analizi<sup>4</sup> kullanılmıştır. Öncelikle üç değişkenin kovaryans matrisi hesaplanmış ve bu matrisin özvektörleri bulunmuştur. Üç özvektörün sütunlarını oluşturduğu W özvektör matrisi ile üç değişkenin sütunlarından oluşan X'in matris çarpımı bize X'in temel bileşen matrisi PC(X)'i sağlayacaktır.

$$PC(X) = XW \quad (17)$$

Aykırılık endeksi, AI, bu üç aykırılık istatistiğinin birinci temel bileşeni, yani PC(X)'in birinci sütunudur. Tablo 10, 7 farklı Senaryo için aykırılık endeksinin dağılım istatistikleri göstermektedir.

**Tablo 10. Senaryolardan Elde Edilen Aykırılık Endeksi (AI) İstatistikleri**

SENARYO	GÖZLEM SAYISI	MIN.	MAKS.	MED.	ORT.	ST SAP.	ÇARP.	BASIK.
1	38513	-2.24	11.36	-0.59	0.00	1.60	1.07	3.17
2	8512	-13.06	14.70	0.00	0.00	1.64	0.14	13.02
3	118231	-2.32	6.34	-0.44	0.00	1.64	1.04	3.34
4	8397	-2.47	11.57	-0.24	0.00	1.44	1.07	4.87
5	891	-2.34	6.19	-0.16	0.00	1.42	2.00	7.88
6	131802	-0.93	20.96	-0.78	0.00	1.71	2.57	10.35
7	4658	-0.78	25.64	-0.42	0.00	1.66	5.64	41.03

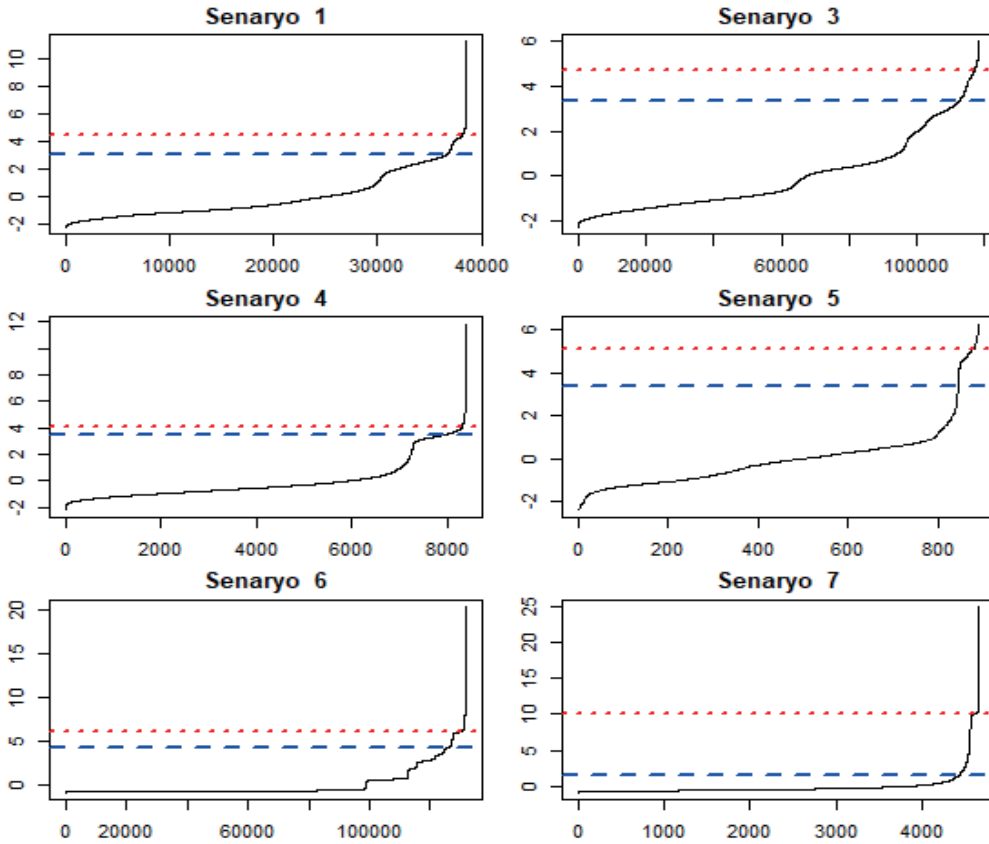
Bu sonuçlara ek olarak, Tablo 8 ve 9'un son üç sütununda görüldüğü gibi AI her üç istatistik ile de çoğunlukla %90 üzeri korelasyon göstermektedir. Bu gözlem, Aykırılık endeksinin her üç istatistiğinin ayrı ayrı sağladığı aykırılık bilgisini içermekte olduğunu ve bu bilgileri tek bir istatistik içinde özetleyebildiğini göstermektedir.

4 Principal Component Analysis (PCA)

Aykırı gözlemler aykırılık endeksinin eşik noktasını geçtiği gözlemler olarak tanımlanmıştır. Eşik noktasının belirlenmesinde iki husus önemlidir. İlk olarak, istatistiğin dağılımındaki ani ayrışma ve kırılma noktaları gözlemlenmelidir. Bu noktalar eşik noktası adaydırlar. İkinci nokta ise aykırı gözlemleri incelemenin zaman ve emek maliyetidir. Örneğin işleme giren çeklerin %20'sinden fazlasını detaylı inceleyip istihbarat raporu oluşturmanın maliyeti faktoring firmasının bütçesini aşarsa eşik değeri %20 ya da daha az olmalıdır. Sonrasında Bölüm 8'de bu eşik seviyesinin optimizasyonu anlatılacaktır.

Şekil 6 altı farklı senaryo ve tüm gözlemler için hesaplanmış sıralı aykırı endeks değerlerini 95 ve 99 percentil değerleri ile birlikte vermektedir. Senaryo 2 ise müşteri temsilcisi görev süresine göre ay bazında incelenecektir. Endeksin 95 ve 99 percentil değerleri endeksin ani artışa geçtiği kırınım noktalarını çoğunlukla yakalamaktadır.

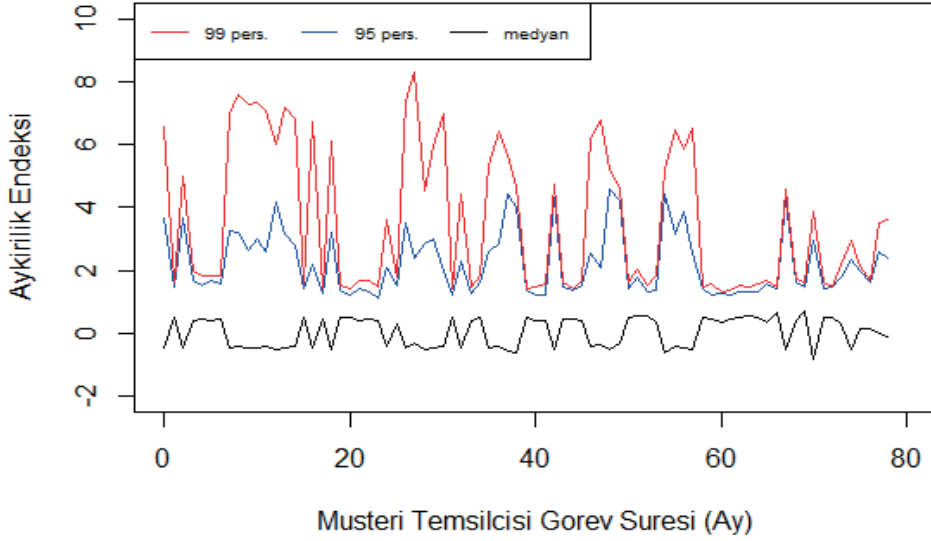
**Şekil 6. Senaryolardan Elde Edilen Aykırı Değer İstatistikleri ve Eşik Değerleri**



Not: Mavi kesikli (kırmızı noktalı) çizgi aykırılık endeksinin 95 (99) percentil göstermektedir.

Şekil 7 ise Senaryo 2 için aykırılık analizini müşteri temsilcisi görev süresine göre ay bazında gerçekleştirmektedir. Aykırılık endeksinin medyan, 95 persentil ve 99 persentil değerleri ay bazında hesaplanmıştır.

**Şekil 7. Senaryo 2 için Müşteri Temsilcisi Görev Süresine Göre Aykırı Değer İstatistikleri**



Modelin değerlendirilmesi için öncelikle uygun  $\alpha$  persentil eşik seviyesi kullanılarak aykırı olarak tespit edilen gözlemler ( $\{\hat{I}(x_i) = 1\}$ ) bulunur. Sonrasında şirketteki faktoring uzmanları tarafından tüm gözlemler zaman içinde analiz edilir ve "Sorunlu" olanlar işaretlenir ( $\{I(x_i) = 1\}$ ). Gözetimsiz olan bu analizde "Sorunlu" durumlar karşılıksız çeklerden, sahteciliğe ve veritabanı hatalarına kadar pek çok farklı konuda gerçekleşebilir. Gözetimli analizde olduğu gibi kesin bir durum işaretlenmediğinden, gözetimsiz analizde olduğu gibi oluşacak durumlar hakkında mükemmel tahminler yapmak değil, veri setinin daha iyi anlaşılmasına destek olmaktadır. Modelin senaryo bazında değerlendirilmesi, her senaryo için doğru sınıflandırılan gözlemlerin sayısının ( $\{I(x_i) = \hat{I}(x_i)\}$ ) toplam gözlemlere oranını belirten doğruluk oranı (accuracy) istatistiği ile bulunmaktadır.

Modelin değerlendirilmesi, farklı senaryolara ait sonuçlar, aykırı model gözlem sayısı, 95 persentil eşik seviyeleri ve doğruluk oranları ile birlikte Tablo 11'de verilmiştir. Her senaryo için oluşturulan gözetimsiz modellerin ortalama %85-%90 civarı makul seviyede bir doğruluk oranı ile çalıştığı saptanmıştır. Yalnızca çekleri inceleyen 6 numaralı senaryoda doğruluk oranı % 92'ye kadar çıkmaktadır.

**Tablo 11. Senaryo Aykırı Değer Analizleri**

SENARYO	TOPLAM GÖZLEM SAYISI	95 PERSENTİL EŞİK DEĞERİ	AYKIRI GÖZLEM SAYISI	DOĞRULUK ORANI
1	38513	2,95	1926	0,82
2	8512	3,38	4100	0,89
3	118231	3,20	5912	0,86
4	8397	3,48	420	0,87
5	891	3,52	45	0,85
6	131802	3,96	6591	0,92
7	4658	1,45	233	0,85

## 8. Model Eşik Seviyesinin Kalibrasyonu

Modelin şirketin maliyet hesaplarına uygun şekilde kalibre edilmesi ve optimal eşik seviyesinin bulunması için hataların birim maliyeti önemlidir. Aykırı gözlemlerde tip 1 hata sayısının  $N_1$  ve tip 2 hata sayısının  $N_2$  olduğunu ve bu hataların maliyetlerinin sırasıyla  $C_1$  ve  $C_2$  olduğunu kabul edelim. O zaman model başarılı senaryo tanımlamaları ile toplam hata maliyeti olan  $N_1C_1 + N_2C_2$  terimini küçültmeyi amaçlar. Zaten uygun senaryolar seçilerek kalibre edilen modelde bu maliyetin ayarlanması senaryolar bazında eşik seviyeleri,  $d_\alpha$  optimal olarak seçilerek yapılacaktır.


Modelde  $N$  çek başvurusu sonrasında aykırı gözlemlerin sayısının  $N_0$  olduğunu ve her aykırı gözlem için  $C_0$  birim maliyeti ile istihbarat raporu oluşturulduğu ve istihbarat için şirketin  $K$  miktarında bütçe ayırdığı varsayılırsa, optimizasyon problemi şu şekilde oluşur:

$$\begin{aligned} \min_{\{d_\alpha\}} \{N_1(d_\alpha)C_1 + N_2(d_\alpha)C_2\} \\ N_0C_0 \leq K \end{aligned} \quad (18)$$

Müşterilere ait  $S_1, S_3, S_4, S_5$  ve  $S_7$  senaryoları üzerinden 18 nolu denklemde verilen optimizasyon problemi üzerinde çalışılmıştır. Şirket tarafından verilen bilgiye göre, bütçe kısıtlamalarının sabit bir  $K$  bütçesi ile değil  $\alpha = \frac{N_0}{N}$  persentil eşik seviyesi üzerinden planlandığı belirtilmiştir. Bu oranın şirket tarafından %10 civarında planlandığı ve en fazla %20 seviyesine kadar çıkabileceği belirtilmiştir. Yine şirket tarafından Tip 2 hata durumunda (Hatalı Negatif) herhangi bir sebeple karşılıksız çıkıp ödenmeyen bir müşteri çekinin zararının ( $C_2$ ), Tip 1 hata durumunda (Hatalı Pozitif) durumunda reddedilen müşteriden kaybolan işlem karının ( $C_1$ ) yaklaşık 10 katı olduğu belirtilmiştir.

Şirket tarafından sunulan veriler ve parametreler hakkındaki bilgilere göre optimizasyon problemi hesaplanmıştır. Parametreler  $C_1 = 1, C_2 = 10, \alpha \leq 20\%$  olarak kabul edilmiş ve basitleştirici bir varsayım olarak tüm modeller için ortak aykırılık eşik yüzdesi kullanılmıştır. Dolayısıyla senaryo bazında eşik seviyesi senaryo aykırılık endeksinin  $100\% - \alpha$  persentil değeri olarak saptanmıştır. Şekil 8 %1 ile %20 arasındaki aykırılık eşik seviyesine göre 5 müşteri bazlı aykırılık senaryosunun toplam hata maliyetini göstermektedir. Görüldüğü üzere %12 eşik seviyesi toplam maliyeti minimize eden optimal seviyeyi göstermektedir. Bu sonuç şirketin şu an aykırı gözlemleri ayırmak ve incelemek için uygulamayı planladığı %10 eşik seviyesine çok yakındır.

**Şekil 8. Eşik Seviyesi Değişiminin Toplam Müşteri Hata Maliyetine Etkisi**



Modelin sağlamlığı (robustness) konusundaki beklenti aykırılık endeksinin  $\alpha$  persentil seviyesi olarak belirlenen aykırı değer eşik noktasının zaman içinde stabil olmasıdır. Model Şirket'te tam zamanlı kullanım aşamasına geçtikten sonra yeni veri akışıyla eşik noktası yukarı ya da aşağı çekilerek modelin yeniden kalibre edilmesi gerekebilir. Model gözetimsiz yapıda olduğundan, eşik seviyesi başlangıçta bir kez belirlendikten sonra sıklıkla revize ve kalibre edilmemelidir. Zaman içinde stabil olmayan eşik seviyeleri, senaryoların tanımlanmaları ve seçilen değişkenler konusunda sorunlar olduğunu gösterebilir.



## 9. Sonuç

Finansal sektördeki dijital platform ve internet üzerinden işlemler arttıkça oluşan riskleri kontrol etmek gittikçe zorlaşmakta ve beklenmedik olaylar sıklaşmaktadır. Bu çalışma hedef değişkenin işaretlenmesinin ve gözetimli model kurulmasının güç olduğu olduğu durumlarda şirketlere aykırı olayların hızlı ve düşük maliyetli tespiti için senaryo bazlı aykırılık analizi çerçevesi çizmektedir.

Bu çalışma parametrik modelleme yapmadan şirket uzmanlarının alan bilgisinden azami ölçüde istifade ederek senaryo bazlı yaklaşımla aykırı gözlemleri bulmayı amaçlamaktadır. Çalışmanın öngördüğü metodolojide, öncelikle bir şirketin uzman analistleri kurguladıkları risk senaryolarında uygun değişkenleri ve bunların transformasyonlarını seçerler. Bu senaryolar ve değişkenler üzerinden oluşturulan aykırılık endeksi ile; ticari işlemlerdeki anomalileri daha çabuk, daha doğru ve daha az maliyetle tespit etmek, ticari ve operasyonel riskleri azaltmak, operasyonel verimliliği arttırmak ve iç kontrol sürecinin etkinliği arttırmak mümkün olabilecektir. Aykırı gözlemlerin sonuçları ve sebepleri zaman içinde daha iyi anlaşıldığında gözetimli yapıda dolandırıcılık, kredi riski, iç performans, ve satış modellerinin geliştirilmesi veya var olan modellerin revize edilmesi de mümkün olacaktır.

Çalışmada Tam Finans tarafından sağlanan ve 2018-2020 yılları arasını kapsayan çek veritabanı kullanılmıştır. Şirketin ArGe departmanından Analitik Pazarlama ve Krediler alanında tecrübeli müdür ve koordinatörler yedi farklı risk senaryosu kurgulamışlar ve uygun değişkenleri ve değişken transformasyonlarını seçmişlerdir. Çalışmada bu senaryolar için üç farklı uzaklık ölçütü hesaplanmış ve temel bileşen analizini kullanarak her gözlem için tek ve ortak bir aykırılık endeksi elde edilmiştir. Bu endeksin 95 persentil değeri eşik olarak alınarak tanımlanan aykırı gözlemlerin şirket veritabanında "Sorunlu" olarak işaretlenen gözlemleri yüksek doğruluk oranı ile tespit edebildiği gösterilmiştir. Ayrıca yine şirket verisi kullanılarak model kalibre edilmiş ve tip 1 ve tip 2 hata oranları ve maliyetleri gözetilerek optimal eşik seviyesi %12 olarak bulunmuştur.

Bu araştırmada uygulama amacıyla faktoring işlemleri ile çalışılmış ise de sunulan metodoloji herhangi bir finansal işlem için kolaylıkla kullanılabilir. Daha da önemlisi Finans sektöründe senaryo bazlı aykırı değer modelinden piyasa ve sektör düzenleyici kurumlar da faydalanabilirler. Piyasayı düzenlemek ve mevduat sahiplerini ve yatırımcıları beklenmedik risklerden korumak amacıyla Bankacılık, Düzenleme ve Denetleme Kurumu (BDDK), Borsa İstanbul, Mali Suçları Araştırma Kurulu (MASAK), Sermaye Piyasası Kurulu (SPK) ve Tasarruf Mevduatı Sigorta Fonu (TMSF) gibi kurumlar risk bazlı senaryolarla bu makaledeki aykırı gözlem metodolojisini uyarlayıp erken uyarı ve denetleme sistemleri geliştirebilirler.

## Kaynakça

1. Alpu, Ö. (2016). Aykırı değer varlığında hızlı minimum kovaryans determinantı kestiricilerinin faktör analizinde kullanımı. *Sakarya University Journal of Science*, 20(3), 701-709.
2. Ané, T., Ureche-Rangau, L., Gambet, J. B., & Bouverot, J. (2008). Robust outlier detection for Asia–Pacific stock index returns. *Journal of International Financial Markets, Institutions and Money*, 18(4), 326-343.
3. Aydın, O. M., & Aktaş, R. (2020) Detecting Financial Information Manipulation By Using Supervised Machine Learning Technics: SVM, PNN, KNN, DT. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, (29), 165-174.
4. Breunig, M. M., Kriegel, H. P., Ng, R. T., & Sander, J. (2000). LOF: identifying density-based local outliers. In *Proceedings of the 2000 ACM SIGMOD international conference on Management of data* (pp. 93-104).
5. Campello, R. J., Moulavi, D., Zimek, A., & Sander, J. (2015). Hierarchical density estimates for data clustering, visualization, and outlier detection. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 10(1), 1-51.
6. Cao, B., Mao, M., Viidu, S., & Yu, P. (2018). Collective fraud detection capturing inter-transaction dependency. In *Proceedings of the KDD 2017 Workshop on Anomaly Detection in Finance* (pp. 66-75).
7. Chawla, S., & Gionis, A. (2013). k-means–: A unified approach to clustering and outlier detection. In *Proceedings of the 2013 SIAM International Conference on Data Mining* (pp. 189-197). Society for Industrial and Applied Mathematics.
8. Cho, S., Hong, H., & Ha, B. C. (2010). A hybrid approach based on the combination of variable selection using decision trees and case-based reasoning using the Mahalanobis distance: For bankruptcy prediction. *Expert Systems with Applications*, 37(4), 3482-3488.
9. Çetiner, M., Dinçsoy, Ö., & Toraman, T. (2020, October). Outlier Detection for Analysis of Real Estate Price. In *2020 28th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
10. Devlin, S. J., Gnanadesikan, R., & Kettenring, J. R. (1975). Robust estimation

- and outlier detection with correlation coefficients. *Biometrika*, 62(3), 531-545.
11. Devlin, S. J., Gnanadesikan, R., & Kettenring, J. R. (1981). Robust estimation of dispersion matrices and principal components. *Journal of the American Statistical Association*, 76(374), 354-362.
  12. Duan, L., Xu, L., Liu, Y., & Lee, J. (2009). Cluster-based outlier detection. *Annals of Operations Research*, 168(1), 151-168.
  13. Esen, M. F., & Timor, M. (2019). Çok Değişkenli Aykırı Değer Tespiti İçin Klasik Ve Dayanıklıklı Mahalanobis Uzaklık Ölçütleri: Finansal Veri İle Bir Uygulama. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, (25), 267-282.
  14. Eskin, E., Arnold, A., Prerau, M., Portnoy, L., & Stolfo, S. (2002). A geometric framework for unsupervised anomaly detection. In *Applications of data mining in computer security* (pp. 77-101). Springer, Boston, MA.
  15. Gnanadesikan, R., & Kettenring, J. R. (1972). Robust estimates, residuals, and outlier detection with multiresponse data. *Biometrics*, 81-124.
  16. Jiang, S. Y., & An, Q. B. (2008). Clustering-based outlier detection method. In *2008 Fifth International Conference on Fuzzy Systems and Knowledge Discovery* (Vol. 2, pp. 429-433). IEEE.
  17. Karminsky, A. M., & Khromova, E. (2018). Increase of banks' credit risks forecasting power by the usage of the set of alternative models. *Russian Journal of Economics*, 4, 155.
  18. Knox, E. M., & Ng, R. T. (1998). Algorithms for mining distancebased outliers in large datasets. In *Proceedings of the international conference on very large data bases* (pp. 392-403).
  19. Kriegel, H. P., Schubert, M., & Zimek, A. (2008). Angle-based outlier detection in high-dimensional data. In *Proceedings of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 444-452).
  20. Mahalanobis, P. C. (1936). On the generalised distance in statistics. *Proceedings of the National Institute of Sciences of India*, 1936, 49-55.
  21. Maronna, R. A. (1976). Robust M-estimators of multivariate location and scatter. *The annals of statistics*, 51-67.

22. Maronna, R. A., Martin, R. D., Yohai, V. J., & Salibián-Barrera, M. (2019). Robust statistics: theory and methods (with R). John Wiley & Sons.
23. Maronna, R. A., & Zamar, R. H. (2002). Robust estimates of location and dispersion for high-dimensional datasets. *Technometrics*, 44(4), 307-317.
24. Moh'd Belal, A. Z., Al-Dahoud, A., & Yahya, A. A. (2010). New outlier detection method based on fuzzy clustering. *WSEAS transactions on information science and applications*, 7, 681-690.
25. Prakash, A., & Chandrasekar, C. (2012). A novel hidden Markov model for credit card fraud detection. *International Journal of Computer Applications*, 59(3), p35-41.
26. Rahmani, A., Afra, S., Zarour, O., Addam, O., Koochakzadeh, N., Kianmehr, K., & Rokne, J. (2014). Graph-based approach for outlier detection in sequential data and its application on stock market and weather data. *Knowledge-Based Systems*, 61, 89-97.
27. Ramaswamy, S., Rastogi, R., & Shim, K. (2000). Efficient algorithms for mining outliers from large data sets. In *Proceedings of the 2000 ACM SIGMOD international conference on Management of data* (pp. 427-438).
28. Rousseeuw, P. J. (1985). Multivariate estimation with high breakdown point. *Mathematical statistics and applications*, 8 (283-297), 37.
29. Rousseeuw, P. J., & Van Zomeren, B. C. (1990). Unmasking multivariate outliers and leverage points. *Journal of the American Statistical association*, 85(411), 633-639.
30. Rousseeuw, P. J., & Driessen, K. V. (1999). A fast algorithm for the minimum covariance determinant estimator. *Technometrics*, 41(3), 212-223.
31. Rousseeuw, P. J., & Leroy, A. M. (2005). Robust regression and outlier detection (Vol. 589). John Wiley & Sons.
32. Sánchez, D., Vila, M. A., Cerda, L., & Serrano, J. M. (2009). Association rules applied to credit card fraud detection. *Expert systems with Applications*, 36(2), 3630-3640.
33. Tang, B., & He, H. (2017). A local density-based approach for outlier detection. *Neurocomputing*, 241, 171-180.

34. Weekley, R. A., Goodrich, R. K., & Cornman, L. B. (2010). An algorithm for classification and outlier detection of time-series data. *Journal of Atmospheric and Oceanic Technology*, 27(1), 94-107.
35. Wiens, D. P., & Zheng, Z. (1986). Robust M-estimators of multivariate location and scatter in the presence of asymmetry. *Canadian Journal of Statistics*, 14(2), 161-176.

## Ek 1. Kredi Kayıt Bürosu Veritabanı

### A. Çek Raporu Değişkenleri

- Referans numarası
- Firma unvanı
- Vergi kimlik numarası
- İbraz edilen çek adedi
- İbrazında ödenen çek adedi
- İbrazında ödenen çeklerin tutarı
- Arkası yazılan ve halen ödenmemiş çek adedi
- Arkası yazılan ve halen ödenmemiş çek tutarı
- Arkası yazılan ve sonradan ödenen çek adedi
- Arkası yazılan ve sonradan ödenen çek tutarı
- İbraz edilen ilk çekin tarihi
- İbraz edilen ve arkası yazılan ilk çekin tarihi
- İbraz edilen ve arkası yazılan son çekin tarihi
- 1 ay içerisinde vadesi dolacak çek toplamı
- 3 ay içerisinde vadesi dolacak çek toplamı
- 6 ay içerisinde vadesi dolacak çek toplamı
- 12 ay içerisinde vadesi dolacak çek toplamı
- 12 aydan daha uzun zamanda vadesi dolacak çek toplamı
- Açık (Ödenmeyen) çek adedi
- Toplam vadeli çek adedi
- Sisteme dönmeyen çek adedi

### B. Risk Raporu Değişkenleri

- Referans numarası
- Firma unvanı
- Vergi kimlik numarası
- Bireysel kredi bilgileri
  - Kredi türü
  - Açılış tarihi
  - Kapanış tarihi

- İdari/kanuni takip tarihi
- Kredi tutarı / limiti
- Ödeme performansı tarihçesi (18 ay)
- Toplam borç
- Gecikmedeki borç
- Bireysel Kredi Notu (BKN)
- Ticari Nitelikli Kredi Bilgileri
  - Limit risk bilgileri
    - Bildirimde bulunan finans kuruluşu sayısı
    - İlk kredi kullanım tarihi
    - Son kredi kullanım tarihi
    - Gecikmedeki hesap sayısı
    - En güncel limit tahsis tarihi
    - Gecikmedeki bakiye toplamı
  - Toplam limit ve borç bakiyeleri
    - Toplam Nakdi Limit ve Borç
    - Toplam gayrinakdi limit ve borç
    - Toplam diğer limit ve borç
  - Takibe alınmış krediler
    - Bildirimde bulunan finans kuruluşu
    - Takibe alındığı tarihteki kredi bakiyeleri
    - Toplam güncel kredi bakiyesi
    - En yakın tablie alınma tarihi
    - En eski takibe alınma tarihi
- Leasing – Faktoring Kredileri
  - Canlı krediler – leasing
  - Canlı krediler – faktoring
  - Takibe alınmış krediler – leasing
  - Takibe alınmış krediler – faktoring