



# Kredi Temerrüt Riskini Tahmin Etmede Makine Öğrenme Algoritmalarının Karşılaştırılması

Toprak Enes Tütüncü<sup>1</sup>, Sevda Gürsaka<sup>2\*</sup>

<sup>1</sup> Bursa Uludağ Üniversitesi, S.B.E.Ekonometri Bölümü YL Öğrencisi, Bursa, Türkiye (ORCID: 0000-0002-8822-584X), [toprakenesutuncu@yahoo.com](mailto:toprakenesutuncu@yahoo.com)

<sup>2\*</sup> Bursa Uludağ Üniversitesi, İİBF, Ekonometri Bölümü, Bursa, Türkiye (ORCID: 0000-0002-1324-3648), [sdalgic@uludag.edu.tr](mailto:sdalgic@uludag.edu.tr)

(İlk Geliş Tarihi 06 Haziran 2022 ve Kabul Tarihi 25 Mart 2023)

(DOI: 10.31590/ejosat.1171611)

**ATIF/REFERENCE:** Tütüncü, T.E., Gürsaka, S. (2023). Kredi Temerrüt Riskini Tahmin Etmede Makine Öğrenmesi Algoritmalarının Karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (50), 14-22.

## Öz

Bankalar ve çeşitli finans kuruluşları tarafından karşılanan kredilerin, müşteri tarafından geri ödenememesi hem kredi veren kuruluşun sermaye kaybını hem de genel ekonomide oluşabilecek çeşitli risk faktörlerini beraberinde getirmektedir. Bu süreçte, oldukça kritik öneme sahip olan kredi riskinin doğru yönetilebilmesi ve uluslararası finans istikrarının sağlanması için Basel Komitesi ve BDDK (Bankacılık Düzenleme ve Denetleme Kurumu) gibi finans denetimi kuruluşları, kredi veren kurumların kredi verme karar aşamasında çeşitli regülasyon politikaları belirlemektedir. Ayrıca, kredi veren kurumlar analitik risk birimleri aracılığıyla kredi değerlendirme modelleri geliştirerek, müşterilere ait kredi risk skorunu hesaplamaktadır.

Bu çalışmada makine öğrenmesi yöntemiyle kredi skorlama sistemlerinde kullanılacak en başarılı tahmini gerçekleştiren algoritmanın belirlenmesi amaçlanmıştır. Bu kapsamda, Gradyan Artırma, Yapay Sinir Ağları, Lojistik Regresyon, Rassal Orman, Karar Ağacı, Destek Vektör Makineleri, K-En Yakın Komşu ve WOE dönüşümleriyle Lojistik Regresyon algoritmaları için modeller kurulmuş ve temerrüde düşen ve temerrüde düşmeyen müşteriler için en iyi sınıflandırma performansı gösteren Gradyan Artırma algoritması olmuştur.

**Anahtar Kelimeler:** Kredi Riski, Makine Öğrenmesi, Gradyan Artırma, Yapay Sinir Ağları, Lojistik Regresyon, Rassal Orman, Karar Ağacı, Destek Vektör Makineleri, K-En Yakın Komşu

## Predicting Default Probability in Credit Risk with Machine Learning Algorithms

### Abstract

Failure to repay the loans provided by banks and various financial foundations by the customer, entails both the capital loss of the lending institution and various risk factors that may occur in the general economy. In this context, financial control institutions such as the Basel Committee and BRSA (Turkish Banking Regulatory and Supervision Agency) have determined various regulatory policies during the phase of lending decision of the lending institutions in order to ensure the appropriate management of loan risk, which have critical importance, and to ensure international financial stability. In addition, lending institutions develop credit evaluation models via analytical risk units and calculate the credit risk score of customers.

In this study, it is aimed to determine the algorithm that makes the most successful estimation that can be used in credit scoring systems with the machine learning method. Within this scope, models for algorithms with Gradient Boosting, Artificial Neural Networks, Logistic Regression, Random Forest, Decision Tree, Support Vector Machines, K-Nearest Neighbor and WOE transformations Logistic Regression were established and Gradient Boosting algorithm has shown the best classification performance for defaulters and non-defaulters.

**Keywords:** Credit Risk, Machine Learning, Gradient Boosting, Neural Network, Logistic Regression, Random Forest, Decision Tree, Support Vector Machine, K-Nearest Neighbor

\* Sorumlu Yazar: [sdalgic@uludag.edu.tr](mailto:sdalgic@uludag.edu.tr)

## 1. Giriş

BDDK'ya göre kredi riski, kredi müşterisinin yapılan sözleşme gereklerine uymayarak yükümlülüğünü kısmen veya tamamen zamanında yerine getirememesinden dolayı bankanın maruz kalabileceği zarar olasılığı olarak tanımlanmıştır (BDDK,2012). Jorion, "Financial Risk Manager Handbook, Wiley Finance Series" adlı eserinde kredi riski için karşı tarafın sözleşmeden doğan yükümlülüklerini yerine getirememesinden kaynaklanan ekonomik kayıp risk olarak tanımlamıştır (Jorion, 2009). Mandacı, "Türk Bankacılık Sektörünün Taşıdığı Riskler ve Finansal Krizi Asmada Kullanılan Risk Ölçüm Teknikleri" çalışmasında kredi riskini, ödenmeme veya geç ödemeden dolayı net kar ve özvarlığın piyasa değerindeki olası değişim olarak ifade etmiştir. (Mandacı, 2003).

Yanlış müşteri seçimi, sözleşmedeki eksiklikler, müşterinin mali gücünün sorumluluklarını yerine getiremeyecek kadar yetersiz olması, gelir/borç ödeme dengesine uymayacak kadar yüksek kredi limiti tahsisi, alınan teminatların yetersiz olması ve ekonomik faktörler nedeniyle krediler tahsil edilememe riski taşımaktadır (Bhargava, 2000). Sonuç olarak kredi riski, banka ile müşteri arasında yapılan kontrat gereği müşterinin üstlendiği yükümlülüklerini sözleşmede belirlenen süre zarfında eksiksiz yerine getirememe durumudur. Diğer bir ifadeyle, müşterinin bankadan almış olduğu faizli kredinin sözleşme yükümlülüklerine göre zamanında bankaya geri ödeyememe (temerrüde düşme) durumudur.

Bankaların finansal getirileri göz önünde bulundurulduğunda, kredi riski için ayrılan likidite ile diğer risk tipleri için ayrılan likidite arasında yüksek fark vardır. Dolayısıyla banka için kredi riskinin diğer risklere kıyasla daha önem arz ettiği söylenebilir. Kredi riski, bankaların karşılaştığı en büyük risktir (Apostolik, 2009). Yanlış kredi risk politikalarının, finansal ve finansal olmayan sektörler üzerinde ciddi izler bırakması sonucu risk ölçümünün önemi ön plana çıkarak, bankacılık risklerine yönelik düzenlemelerle ilgili uluslararası çalışmaların hız kazanmasına sebep olmuştur. Bu bağlamda kredi temerrüt riskinin belirlenmesi amacıyla birçok araştırma ve analiz tekniği geliştirilmiştir. Bu konuda birçok farklı yaklaşım ortaya atılmıştır. Geleneksel bir yaklaşım olarak kredi temerrüt riskinin tahmininde Lojistik Regresyon ve Diskriminant Analizi gibi teknikler kullanılmakta iken, makine öğrenmesi algoritmaları da yeni bir yaklaşım olarak bu alanda yerini almış ve birçok farklı alanda kullanıldığı gibi kredi riski alanında da uygulamaları artmaya başlamıştır. Makine öğrenmesinin doğru kullanılması ve sonucunda probleme yönelik iyi eğitilmiş ve başarılı olan modellerin tasarlanması halinde, sürekli yenilenen kredilerin başarılı veya başarısız olarak tahmin edilmesi sağlanacak olup bu da finansal kuruluşun kredi risklerini iyi yönetebilmesi açısından son derece önemli olacaktır.

Kredi temerrüt riski tahmininde çok sayıda makine öğrenmesi algoritması kullanılmasına rağmen, hangi tekniğin en iyi performansı sağladığına dair bir görüş birliğine varılamamıştır. Bu sebeple, algoritmalar ile kurulan modellerin sınıflandırma başarıları, çeşitli istatistiksel ve makine öğrenmesi teknikleriyle ölçülerek, en iyi sınıflandırma performansı sağlayan model, optimum model belirlenmektedir.

Literatürde bu konuda yapılmış çeşitli çalışmalar mevcuttur. Bu çalışmalardan birinde Bellotti (2009), Destek Vektör Makineleri algoritmasının, kredi kartı müşterileri sınıflandırılırken kimin temerrüde düşeceğinin hesaplamasında başarılı olduğu ve ayrıca test edildiğinde ve geleneksel tekniklerle kıyaslandığında temerrüt riskini belirlemede en önemli özellikleri keşfetmede rekabetçi oldukları bulunmuştur. Yeh (2009), Kredi skorlamada Diskriminant Analizi, Lojistik Regresyon, Yapay Sinir Ağları, Sınıflandırma Ağaçları ve Bayes sınıflandırıcı gibi birçok algoritmadan yararlandığını, bunlar arasından Yapay Sinir Ağlarının daha doğru sonuçlar verdiğini bulmuştur.

Zhou ve Wang (2012) daha iyi tahmin için karar ağaçlarına ağırlık tahsis etmeyi önermişlerdir. Hamori ve arkadaşları (2018), kredi riski analizinde sinir ağı yöntemleriyle Torbalama (Bagging), Rassel Orman ve Artırma (Boosting) ile tahmin doğruluğu ve sınıflandırma yeteneğini incelemiş ve karşılaştırmıştır. Çalışmada makine öğrenme algoritmaları arasında Artırmanın daha iyi performans sağladığını bulmuşlardır. Temerrüt olasılığının düşük olduğu portföyler, düşük risk olarak kabul edilirken, temerrüde düşen sınıflar arasında bir dengesizlik problemi ile karşılaşılabilir. Sınıf dengesizliği oluşturan portföyler için Gradyan Artırma ve Rassel Karar Ormanları sınıflandırıcı tekniklerinin iyi performans gösterdiği bulunmuştur (Brown, 2012). Zhang (2017)'a göre doğruluk oranı söz konusu olduğunda K-En Yakın Komşu, Rassel Orman ve Yapay Sinir Ağları algoritmaları iyi performans göstermektedir. Barboza (2017) yaptığı çalışmada Torbalama, Artırma ve Rassel Orman benzer prosedürleri içermesine rağmen, Rassel Ormanın genellikle daha iyi doğruluk ve hata oranları ürettiğini ortaya koymuştur.

Kavcıoğlu (2019), kurumsal kredileri skorlamada klasik yöntemler ile yapay sinir ağlarını karşılaştırarak, eğitim veri setinde yapay sinir ağlarının lojistik regresyona kıyasla daha başarılı sonuçlar ürettiğini saptamıştır. Verinin boyutu ve kalitesini dikkate alarak Yapay Sinir Ağları gibi makine öğrenmesi algoritmalarının daha iyi performans gösterdiği bulgusuna ulaşılmıştır. Demirbulut ve arkadaşları (2017), istatistiksel ve makine öğrenmesi algoritmalarıyla kredi skorlama yöntemlerini ele alarak karşılaştırma analizleri yapmışlardır. Sınıflandırma başarısını AUC (Area Under Curve) değeriyle ölçülerek, YSA modelinin en başarılı algoritma olduğu bulgusuna ulaşılmıştır.

Bu çalışmada, müşterilere ait bireysel kredilerin riskini hesaplayarak, temerrüt oranını değerlendirmek amacıyla yedi farklı istatistiksel ve makine öğrenmesi algoritmaları kullanılmıştır. Araştırma kapsamında, modelde öznitelik değişkeni olarak girdi görevi görececek değişkenler farklı değişken indirgeme teknikleri kullanılarak belirlenmiştir. Nihai değişken seçimi için LASSO Regresyonu kullanılmış olup, ilgili tekniğin ceza parametresinin en güçlü sınıflandırıcı öznitelik değişkenlerin keşfedilmesini sağlamıştır. Nihai öznitelik değişkenleri ile temerrüt risk oranının tahminlemesi için Lojistik Regresyon, Yapay Sinir Ağları, Karar Ağacı, Destek Vektör Makineleri, K-En Yakın Komşu, Rassel Orman, Gradyan Artırma ve WOE dönüşümleri gerçekleştirilmiş haliyle Lojistik Regresyon algoritmaları kullanılmıştır. Elde edilen sonuçlar, Doğruluk, Hassasiyet, Özgüllük, Kesinlik, F1 skoru ve ROC eğrisi olmak üzere altı farklı ölçüye göre algoritmalar arasında performans karşılaştırılması yapılmıştır. Analitik veri kalitesi ve model geliştirme süreçlerinde SAS Enterprise Guide ve SAS Enterprise Miner yazılım programları kullanılmıştır.

## 2. Materyal ve Metot

Makine Öğrenme algoritmaları, “eğitim verileri” olarak da bilinen örnek veri setini kullanarak otomatik olarak bir matematiksel model oluşturur ve bu kararları almak için özel olarak programlanma ihtiyacı duymaz. Öğrenmenin en temel örneği verilere düz bir çizginin yerleştirilmesi olabilir, ancak makine öğrenmesi genellikle düz çizgilere göre çok daha esnek modellerle ilgilenir. Bunu yapmasının amacı, modelin öğrenmede kullanılmayan veriler hakkında kendi içinde yeni sonuçlar çıkarmak içindir. (Lindholm, 2019).

Son yıllarda alandaki teknik gelişmeler, verilerin kullanılabilirliğinin artması ve artan bilgi işlem gücünün bir sonucu olarak makine öğrenmesinin yeteneklerinde önemli ilerlemeler görülmüştür. Bu ilerlemelerin bir sonucu olarak, sadece birkaç yıl önce doğru sonuçlar elde etmek için mücadele eden sistemlerin artık belirli görevlerde insanlardan daha iyi performans gösterebileceği kanıtlanmıştır. Günümüzde bazı görevlerde insanlardan daha iyi performans gösterebilen ses ve nesne tanıma sistemleri bulunmaktadır. Örneğin, 2015 yılında araştırmacılar, tek tek el yazısı rakamları tanımaya odaklanan dar bir vizyonla ilgili görevde insan yeteneklerini aşan bir makine öğrenme sistemi oluşturmuşlardır (Markoff, 2015).

Makine öğrenmesi teknikleri denetimli öğrenme, denetimsiz öğrenme, yarı – denetimli öğrenme ve pekiştirmeli öğrenme olarak dört ana başlıkta incelenebilir. Denetimli öğrenmedeki esas amaç, öngörülemeyen veya gelecekteki veriler hakkında tahminlerde bulunmamızı sağlayan etiketli eğitim verilerinden bir model öğrenmektir (Raschka, 2015). Denetimli öğrenme algoritmaları kendi içinde uygulama amaçlarına ve yapılarına göre sınıflandırma, regresyon ve tahmin yaklaşımları şeklinde görevlere ayrılır. Bu çalışmada denetimli makine öğrenmesinin sınıflandırma amacıyla kullanılacaktır.

### 2.1. Çalışmada Kullanılan Sınıflandırma Algoritmaları

Sınıflandırma, hedefin, geçmiş gözlemlere dayalı yeni örneklerin kategorik sınıf etiketlerini öngörmek olduğu, denetimli öğrenmenin bir alt kategorisidir. Bu sınıf etiketleri, örneklerin grup üyelikleri olarak anlaşılabilen ayrık, sıralanmamış değerlerden oluşur (Raschka, 2015). Sınıflandırma amacıyla kullanılan algoritmalar, yapısal veya yapısal olmayan veriler üzerine uygulanarak, gözlemlenen değerlerden bir sonuç çıkarıp yeni gözlemin hangi kategoriye ait olduğunu ikili sınıflandırma, çoklu sınıflandırma veya çoklu etiket sınıflandırma gibi yöntemler kullanarak belirler.

Sınıflandırma yöntemlerinde Lojistik Regresyon, Boosting, Karar Ağacı, Rassal Orman, Naive Bayes, K-En Yakın Komşu ve Destek Vektör Makineleri en çok tercih edilen algoritmalarıdır.

#### 2.1.1. Lojistik Regresyon

Lojistik Regresyon, hedef değişkeninin olası iki değer alması (dikotom) durumunda, öznitelik değişkenlerinin bir lojistik fonksiyon olarak tanımlanması ve hedef değişkeni ile arasındaki ilişkinin regresyon analizi yardımıyla incelenerek, hedef değişkeni için sonucun olasılık değerinin logaritmasının tahmin edilmesidir. Lojistik Regresyonun yapısı doğrusal regresyona benzerlik gösterse de teknik olarak ayrık sınıfları öngören bir sınıflandırma aracıdır. Bu bağlamda, Lojistik Regresyon, özellikle tüketici kredisi endüstrisinde yaygın olarak kullanılan bir algoritmadır (Hand, 2009).

Temerrüt riskinin tahmininde, bir müşterinin kredi ödemelerindeki davranış yapısının iyi veya kötü ödeme durumuna bağlı olarak ikili durumu incelenir. Bu iki yanıt modeli için, hedef değişken  $y$  iki olası değerden birini alabilir: müşteri kötü bir ödeyici ise  $y=1$ ; iyi bir ödeyici ise  $y=0$  (Brown, 2014).

#### 2.1.2. Yapay Sinir Ağları (Artificial Neural Network)

Yapay sinir ağları, hedef ve öznitelik değişkenleri arasındaki ilişkiyi analiz katmanları aracılığıyla işlemek için daha esnek bir tasarım sunan bir makine öğrenme algoritmasıdır. Temel olarak girdi katmanı, gizli (ara) katman ve çıktı katmanından oluşan bir yapıdadır. YSA, biyolojik sinir ağlarını taklit eden sentetik yapılardır (Eğrioğlu, 2009:10590). Dolayısıyla belirlenmiş bir modelin parametrelerini tahmin etmek yerine, beyin gibi biyolojik sinir sistemlerinin bilgi işlem biçiminden ilham alınarak tasarlanmıştır. Bu tasarım esasen insan beyinleri değil, hayvan beyinlerinin paralel mimarisi dikkate alınarak modellenmiştir (Bell, 2014).

Yapay Sinir Ağlarının yapısı, girdiler, ağırlıklar, toplam fonksiyonu, aktivasyon fonksiyonu ve çıkış fonksiyonu olarak beş bölümden oluşmaktadır. YSA üzerindeki her bir nöron, bir işleme alınma durumunu ifade etmektedir. Ağın öğrenme işlemini gerçekleştirmek için dışarıdan veya gereksinime göre diğer hücrelerden nöronlara gelen girdiler ( $X_j$ ), işlenerek bir sonraki nöron için çıkış değerini iletir. Girdilerin çıktı üzerindeki etkisinin hesaplanabilmesi için her bir girdinin eğitim sırasında geldikleri bağlantıların ağırlığıyla çarpılarak bir parametre (ağırlık/ $W_j$ ) üretilir. Çıkan sonuç, girdi değerlerinden bağımsız ve modelin fit edilmesine yardımcı olan bias ( $b$ ) değişkeni ile toplanarak, toplama fonksiyonları (toplam, çarpım, maksimum, minimum, vd.) ile beslenir. Toplama fonksiyonları aracılığıyla, elde edilen net girdi, aktivasyon fonksiyonları (sigmoid, tanjant hiperbolik, doğrusal, relu, vd.) ile beslenerek bir veri çıktısı elde edilir.

Çalışmaya konu olan temerrüt riski tahmininde net girdinin hesaplanması için toplama fonksiyonları arasından ağırlıklı olarak kullanılan toplam fonksiyonu kullanılmıştır. Çıkış katmanındaki aktivasyon fonksiyonu ile bir yanıt olasılığı elde etmek için ise aktivasyon fonksiyonları arasından ikili bir tahminleme olan sigmoid aktivasyon fonksiyonu kullanılmıştır.

#### 2.1.3. Karar Ağacı (Decision Tree)

Denetimli bir öğrenme tekniği olan karar ağaçları hem sınıflandırma hem de regresyon için kullanılabilen, ağaç benzeri bir yapıda düzenlenmiş bir dizi kural tabanlı hiyerarşik bir sınıflandırma algoritmasıdır. Karar ağaçları, heterojen yapıdaki nicel veya nitel veri setlerini, hedef değişkene dayalı homojen alt gruplara ayırarak hedef değişkene ait değerlerin tahminini gerçekleştiren, uygulanabilir

bir model kurmayı hedefler. Örneğin, bir kredi riski vaka çalışmasında, kredi başvurusunda bulunan müşteriye ait borç, yaş, gelir ve medeni durum bilgileri bulunabilir. Karar ağacı, her bir başvuruyu iyi veya kötü bir kredi riski olarak tahmin edebilen (sınıflandırılabilen) bir dizi metin kuralı veya grafiksel bir ağaç olarak bir model oluşturur (Zhang, 2002).

#### 2.1.4. Destek Vektör Makineleri (Support Vector Machine)

Yüksek boyutlara sahip veri türleri için sınıflandırma veya regresyon analizini gerçekleştirmede ekstra avantajlara sahip denetimli öğrenme yöntemi olan Destek Vektör Makineleri, iki sınıfın optimal bölünmesinde karar fonksiyonunun tahmin edilmesi, diğer bir ifadeyle  $n$  boyutlu bir uzayda optimal bir sınıflandırma için hiperdüzlemin belirlenmesine dayanmaktadır. Destek Vektör Makineleri, doğrusal ayrılabilen ve doğrusal ayrılamayan veri türleri için farklı prensipler sunmakla birlikte, bu çalışma kapsamında kullanılan doğrusal ayrılabilen DVM incelenecektir.

#### 2.1.5. K-En Yakın Komşu (K-Nearest Neighbour)

K-En Yakın Komşu algoritması, sınıflandırma ve regresyon için kullanılan parametrik olmayan bir denetimli öğrenme tekniğidir. Eğitim sürecini verilerin kaydını tutarak gerçekleştirdiğinden diğer makine öğrenme yöntemlerine göre daha tembel bir öğrenme tekniğine sahiptir. Basit yapılarına rağmen, uydu görüntüleri, el yazıları, elektrokardiyogram görüntüleri gibi birçok sınıflandırma çalışmalarında başarılı sonuçlar elde etmektedir. Algoritma temel olarak, eğitim verilerinin özellik uzayındaki belirli bir  $k$  hiperparametresine olan uzaklığına göre oluşturulan sınıflandırmanın, örnek tabanlı öğrenmesine dayanmaktadır.

K-En Yakın Komşu algoritmasının optimum sonuç üretmesi için en uygun uzaklık matrisinin hesaplanmasına ve optimal sınıflandırmayı sağlayacak komşu sayısına ( $k$  hiperparametresine) ihtiyaç vardır. Eğitim veri setindeki gözlemler arasındaki mesafenin tanımlanması ve optimal uzaklık matrisinin hesaplanması için Öklid, Manhattan, Minkowski, Mahalanobis, Kosinüs, Jaccard, Hamming gibi yöntemler kullanılmaktadır.

#### 2.1.6. Rassal Orman (Random Forest)

Topluluk Öğrenmesine dayanan Rassal Orman (RO) algoritması, Torbalama (Bootstrap Aggregation) tekniğinden yararlanarak, herhangi bir bilgi ölçüsü metodu kullanmadan seçilen rastgele örneklemeler ve değişkenlerle inşa edilen karar ağaçları topluluklarıdır. Rassal Orman, torbalama tekniği ile seçilen rastgele örneklemelere ek olarak, ağacın her düğümünde rastgele seçilen değişkenler ile karar ormanını oluşturur. Dolayısıyla Rassal Orman, torbalama yönteminin gelişmiş bir şekli olarak kabul edilebilir (Breiman, 2001).

Ek olarak, RO algoritması eğitim veri setinin belirli bir kısmını ağaçlardan elde edilen sonuçların hata oranlarını değerlendirmek için kullanır. (Out-of-Bag, OOB) olarak adlandırılan bu veri seti, ormana ait genel sınıflandırma başarısını da hata skoruyla tespit ederek, model doğruluğunu ölçümlenebilmektedir. Sahip olduğu bu teknikler ile aşırı öğrenme (overfitting) durumuna dayanıklı olsa da gürültülü verilerin yoğunluğuna göre aşırı öğrenme eğiliminde olabilirler. RO, tıpkı Karar Ağaçları ve Gradyan Artırma algoritmaları gibi öznelik değişkenlerinin hedef değişken üzerindeki sınıflandırıcı gücünü kullanarak öznelik önemliliğini hesaplamaktadır.

#### 2.1.7. Gradyan Artırma (Gradient Boosting)

Gradyan Artırma, regresyon veya sınıflandırma modellerinde tahmin edilen değerler ile gözlemlenen değerler arasındaki uyumun iyileştirilmesi için kayıp fonksiyonun türevleri ile model optimizasyonuna izin veren bir makine öğrenme algoritmasıdır. Model optimizasyonunda kullanılan kayıp fonksiyonu için regresyon modellerinde ortalama hata kare kullanılırken, sınıflandırma modellerinde logaritmik kayıp kullanılmaktadır. Algoritmanın ardındaki yeteneği, artıklardaki örüntüleri model tahmininde parametreleştirilmiş bir yapıda kullanarak, zayıf tahminicileri iyileştirmesi ve algoritmik olarak kayıp fonksiyonunu optimize etmesidir. Bu bağlamda, artık değerlerin bir kayıp fonksiyonunun türevleri olarak toplu etkileşimli iterasyonlarla hem varyansı hem de sapmayı azaltacak şekilde bir öngörü fonksiyonunun doğruluğunu artıran kolektif bir algoritmadır.

## 2.2. Sınıflandırmalar için Performans Ölçüleri

Çalışmaya konu olan kredi temerrüt risk tahmininde, temerrüde düşen ve temerrüde düşmeyen olarak ikili sınıflandırmaları gerçekleştiren algoritmaların performansları için karmaşıklık matrisinden elde edilen sınıflandırma ölçüleri ve ROC eğrisinden yararlanılmaktadır.

## 2.3. Veri Kalitesi ve Model Geliştirme

Çalışmada modele girdi olacak veri kümesi, Kaggle'ın açık erişiminde bulunan Home Credit tarafından sağlanmaktadır. Analitik girdileri kapsayan temel veri kümesi, yedi farklı veri setinden meydana gelmektedir. Başvuru veri seti, tüm başvuru sahiplerinin daha önce temerrüde düşüp düşmediği gibi statik verilerin ve demografik bilgilerin bulunduğu diğer bazı bilgileri içerir. Diğer veri setleri kredi bürosundaki önceki başvuru bilgileri, kredi kartı bakiye ve ödeme bilgileri, daha önce alınan kredi bilgileri, müşterilerin daha önce almış olduğu konut kredilerine ait davranışsal bilgileri, önceki konut kredilerine ait ödeme geçmişi bilgileri ve kredi bürosundan gelen aylık davranışsal bilgilerden oluşmaktadır. Bu veri setlerinden elde edilen 1460 açıklayıcı (öznelik) değişken, 307510 gözleme sahiptir. Çalışma kapsamında, hedef değişken değerlerindeki temerrüde düşenler 1, temerrüde düşmeyenler 0 olarak tanımlanmıştır. Uygulama kapsamında, SAS Enterprise Guide ürünü ile analitik girdi veri seti oluşturulmuş ve diğer analitik geliştirmeler ve makine öğrenmesi algoritmaları SAS Enterprise Miner modülleri kullanılarak gerçekleştirilmiştir.

### 2.3.1. Veri Önleme ve Değişken İndirgeme

Analitik modellerde girdi olarak kullanılacak değişkenlerin belirlenmesi, model tahmin gücünü doğrudan etkileyen faktördür. Aynı zamanda girdi olarak kullanılacak gözlemler içinde bu durum geçerlidir. Bu iki perspektifle, temel veri seti üzerinden hem satır (gözlem) hem de sütun (değişken) bazlı indirgeme işlemi bir boyut azaltma tekniğidir. Diğer bir ifadeyle, temel veri seti üzerinden örneklem belirleme ve değişken indirgeme işlemleri, yatay ve dikey perspektifle boyut azaltma teknikleridir.

Bu doğrultuda uygulanan kayıp değer oranı yöntemi kullanılarak mevcutta sahip olunan 1460 değişken içerisinde 461 değişken, eşik değer olarak belirlenen %70'in üstünde kayıp gözleme sahip olduğu tespit edilerek analiz dışı bırakılmıştır. Kullanılan bir diğer değişken indirgeme yöntemi ise Varyans Eşliği yöntemidir. Bu yöntem gereği; eğer bir değişkenin dağılımı yaklaşık sıfır varyans özelliğini taşıyorsa, bu değişkenin hedef değişken üzerinde anlamlı bir etkisi beklenmemektedir. Diğer bir ifadeyle, değişkene ait değerlerin neredeyse tamamı aynı değere sahip ise değişkenin modele katkısının yüksek olmayacağı öngörülmektedir. Bu bağlamda, değişkenlerin dağılımları için 0.01'lik varyans eşik değeri belirlenmiş ve her bir değişkenin kendi içinde %99 oranda aynı değerlere sahip olması durumunda analiz dışı bırakılmasına karar verilmiştir. İncelenen 999 değişken içinden 86 değişkenin %99 oranında aynı değerlere sahip olduğu analiz edilmiştir.

Daha sonra değişken indirgemedeki sıklıkla başvurulan yöntemlerden olan "Kanıtlı Aralığı (Weight of Evidence (WOE))" ve "Bilgi Değeri (IV)" teknikleri ele alınmıştır. Değişkenlerin açıklayıcı ölçütü olarak Bilgi Değeri kullanılmış ve çalışma konusu olan temerrüt olasılığı kapsamında, öznelik değişkenlerinin iyi ve kötü kredileri ayırt etme yeteneğine göre önem sırası oluşturulmuştur. Değişkenlerin ayırıcı gücü için belirlenen 0.1'lik eşik değerinin altında kalan 866 değişken elenerek analiz dışı bırakılmıştır.

Çalışma kapsamında aykırı değerlerin tespiti için her bir açıklayıcı değişkene ait ortalama, minimum, maksimum ve 90'ıncı yüzdeler dilimi incelendiğinde, gözlemler arasındaki değişkenliğin yüksek olduğu belirlenmiştir. Aykırı değerlerin, örnekleme olan etkisini azaltması için 90'ıncı yüzdeler dilimin üzerinde bulunan 11692 gözlem, aykırı değer olarak kabul edilerek analiz dışı bırakılmıştır.

Ham veri setinde bulunan 295818 müşteriye ait sınıf dağılımı incelenmiş ve temerrüde düşmeyenlerin sayısının temerrüde düşenlere oranla yaklaşık 12 kat daha fazla olduğu tespit edilmiştir. Tüm popülasyonun %92'sini oluşturan iyi kredilerin, model geliştirme sürecinde sapmaya neden olmaması için tabakalı örneklem metodolojisiyle her iki sınıftan eşit sayıda örneklem belirlenmiştir.

Veri kalitesi ve model geliştirme bölümünde, nihai örneklem seti üzerinden kayıp değerlerin tahmini ve değişken indirgeme işlemlerine devam edilmiş olup, makine öğrenmesinin temel alt yapısını oluşturan verilerin bölünme işlemi gerçekleştirilmiştir. Bu kontekste, modellerin eğitilmesi ve en iyi ağırlıkların elde edilmesi için veri setinin %60'ı eğitim, eğitilen modellerin aşırı öğrenmesini önlemek ve sınıflandırma performansını değerlendirmek için %20'si doğrulama ve modelin tahmin yeteneğini ölçmek için %20'si test veri seti olarak ayrılmıştır.

Örneklem içinde bulunan 47 değişkene ait kayıp değerlerin oranları tekrar incelenmiş ve belirlenen %30'luk eşik değerinin üstünde kayıp değere sahip olan değişkenler, ağaç tabanlı kayıp değerlerin atamasında daha tutarlı sonuçlar üretmesi için girdi olarak kullanılmamıştır.

Analitik model verisinin geliştirilme sürecine, örneklem veri setindeki kayıp verilerin atama işlemiyle birlikte, değişken indirgeme adımları ile devam edilmiştir. Uygulanan birçok farklı değişken indirgeme teknikleriyle elde edilen 17 değişken arasından, modelleme öncesi nihai değişkenlerin belirlenme işlemi LASSO tekniği ile gerçekleştirilmiştir. K-katlamalı çapraz doğrulama yöntemiyle model performansına ve makine öğrenmesi tekniğine pozitif katkı sağlayan LASSO, geleneksel yaklaşımlara göre makine öğrenmesi tekniklerinde çoklu fayda sağlayan bir teknik haline gelmiştir. Bu bağlamda, eğitim veri seti 10 parçaya bölünerek k-katlamalı çapraz doğrulama ile modelin tahmine dayalı performansı değerlendirilmiştir.

Modellemenin optimal noktasında sahip olunan 9 öngörücü ve nihai model girdi değişkenlerine ilişkin açıklamalarına Tablo 1'de yer verilmiştir. Diğer tüm girdi değişkenleri, katsayı değerlerinin sıfır olması sebebiyle elenerek analiz dışı bırakılmıştır. Ek olarak, nihai girdi değişkenleri için nihai korelasyon kontrolü gerçekleştirilmiş olup, aralarındaki ilişkinin %30'un altında olduğu görülmüş ve herhangi bir elemeye gidilmemiştir.

Tablo 1. Nihai Değişkenler (Table 1. Final Variables)

Öznelik	Açıklama
A_DAYS_EMPLOYED	Başvuru sahibinin ilgili başvurudan kaç gün önce bir iş yerine istihdam edildiği gün sayısıdır
A_EXT_SOURCE_MEAN	İlgili başvuru için harici veri kaynağından elde edilen başvuru sahibine ait skor puanlarının ortalaması
A_LOAN_RATE	İlgili başvuru için istenilen kredi tutarının verilen kredi tutarına oranı
A_RRCWC	İlgili başvuru sahibinin yaşadığı şehri dikkate alarak Home Credit'in bölgedeki reyting oranı
B_CA_A_MEAN	İlgili başvuru sahibinin Kredi Kayıt Bürosundaki aktif olan ortalama kredi sayısının, ödenmemiş kredilerin sayısına oranı

<b>B_DCE_MAX</b>	İlgili başvuru için Kredi Kayıt Bürosundaki aktif olan kredi ürünlerinin ödemelerine kalan maksimum gün sayısı
<b>IP_AP_MIN_MIN</b>	İlgili başvuru sahibinin bir önceki kredide gerçekleştirdiği minimum ödeme miktarının, aktif kredilerine yaptığı minimum ödeme miktarına oranı
<b>PA_NCS_R_MEAN</b>	Önceki başvuruların sözleşmelerine ilişkin ortalama reddedilme oranı
<b>PA_NPRT_W_MEAN</b>	İlgili başvuru sahibinin başvuruda bulunduğu önceki bankada düzenli hesabı bulunmama durumunun ortalaması

### 2.3.2. Model Geliştirme ve Performans Değerlendirme

Çalışmanın bu bölümünde değişken indirgeme teknikleri ile elde edilen nihai öznelik değişkenleri kullanılarak, kredilerin temerrüt riski (0-1) yukarıda ele alınan sınıflandırma algoritmaları ile belirlenmeye çalışılmış ve kullanılan algoritmaların sınıflandırma performansları karşılaştırılmıştır. Belirlenen nihai değişkenler ile eğitim, doğrulama ve test veri setleri üzerinden algoritmalar iyi ve kötü müşterileri sınıflandırarak, karmaşıklık matrisleri elde edilmiştir. Test veri seti üzerinden her bir algoritmaya ait karmaşıklık matrisinden elde edilen sınıflandırma ölçülerinin sonuçlarına aşağıdaki Tablo 2’de yer verilmiştir.


Tablo 2. Sınıflandırma Ölçütleri (Table 2. Classification Metrics)

Model Algoritmaları	Doğruluk	Hassasiyet	Özgüllük	Kesinlik	F1 Skoru
Gradyan Artırma	%68,59	%68,09	%69,09	%68,77	%68,43
Lojistik Regresyon (WOE)	%67,74	%67,10	%68,39	%67,97	%67,53
Yapay Sinir Ağları	%67,71	%67,73	%67,69	%67,70	%67,71
Lojistik Regresyon	%67,11	%65,79	%68,43	%67,57	%66,67
Destek Vektör Makineleri	%67,03	%65,20	%68,85	%67,57	%66,41
Rassal Orman	%66,31	%62,39	%70,23	%67,69	%64,93
Karar Ağacı	%66,56	%66,82	%66,30	%66,47	%66,65
K-En Yakın Komşu	%58,85	%63,13	%54,57	%58,15	%60,53

Yukarıdaki oranlar incelendiğinde, K-En Yakın Komşu algoritması temerrüde düşenler ile temerrüde düşmeyenlerin sınıflandırılmasında diğer algoritmalara görece daha başarısız sonuçlar vermektedir. Sınıflandırma başarısının genel performans bilgisini veren doğruluk oranı için K-En Yakın Komşu algoritması haricinde diğer algoritmalar birbirlerine yakın değerlere sahip olsa da Gradyan Artırma algoritmasının en başarılı sınıflandırma oranına sahip olduğu söylenebilir. Tip-II hata perspektifiyle, gerçekte temerrüde düşen müşteriler için algoritmaların sınıflandırma başarısını ölçen hassasiyet oranı için Gradyan Artırma algoritması en başarılı sonucu verse de Yapay Sinir Ağları algoritması ve WOE’li Lojistik Regresyon algoritmalarıyla yakın oranlara sahiptir. Diğer hata perspektifi (Tip-I) ile algoritmaların temerrüde düşen olarak gerçekleştirdiği sınıflandırma tahmininde ne oranda başarılı olduğu kesinlik ölçüsünde, Gradyan Artırma algoritması diğer algoritmalara görece daha başarılı bir sonuç vermiştir. Temerrüde düşmeyen müşterilerin Tip-I hata perspektifi ile hesaplanan özgüllük ölçüsünde, Rassal Orman algoritmasının sınıflandırma performansı yüksek olsa da genel sınıflandırma başarısı düşük kalmıştır. Ek olarak, bu ölçüde Destek Vektör Makineleri ve Gradyan Artırma algoritmalarının sınıflandırma yeteneklerinin de iyi sonuçlar verdiği görülmüştür. Karmaşıklık matrisinden elde edilen yukarıdaki ölçüler yardımıyla, sınıflandırma başarısının değerlendirilmesinde sıklıkla kullanılan F1 skor oranı hesaplanmış olup, Gradyan Artırma algoritmasının en iyi oranla sınıflandırma yeteneğine sahip olduğu gözlemlenmiştir.


Ek olarak, WOE’li halleriyle kurulan Lojistik Regresyon modelinin, değişkenlerin ham haliyle inşa edilmiş Lojistik Regresyon modeline göre daha başarılı sınıflandırma oranlarına sahip olduğu görülmektedir.

Algoritmaların sınıflandırma performanslarının incelenmesinde kullanılan bir diğer ölçü ROC eğrisi olup, ilgili algoritmaların eğitim, doğrulama ve test verisinden elde edilen ROC eğrilerine aşağıdaki Grafikte yer verilmiştir.



Şekil 1. Eğitim, Doğrulama ve Test Verileri İçin ROC Eğrileri (Figure 1. ROC Curves for Train, Validate, and Test Data)

Algoritmaların, eğitim, doğrulama ve test veri setleriyle temerrüde düşen ve temerrüde düşmeyen müşteriler için gerçekleştirmiş olduğu sınıflandırma yetenekleri, ROC eğri oranlarıncı incelenmiş olup, modellerin sınıflandırma uyumunda aşırı öğrenme veya eksik öğrenme davranışı görülmemiştir. Modellerin performans gücü değerlendirmeleri, test verisinden elde edilen ROC eğrisinin altında kalan alanın büyüklüğüne göre belirlenmiştir.



Şekil 2. Test Verisi İçin ROC Eğrileri (Figure 2. ROC Curves for Test Data)

Bu kapsamda, Hassasiyet ve 1-Özgüllük oranlarının farklı eşik değerlerine göre hesaplanan ROC eğrisi incelendiğinde, K-En Yakın Komşu algoritmasının diğer algoritmalara göre daha az başarılı bir sınıflandırma oranına sahip olduğu görülmektedir. İlgili görseldeki algoritmaların ROC eğri oranlarına aşağıda yer verilmiştir.

Tablo 3. ROC Eğri Oranları-AUC (Table 3. ROC Curve Ratios-AUC)

Model Algoritmaları	ROC Eğrisi
Gradyan Artırma	0,75
Lojistik Regresyon (WOE)	0,74
Yapay Sinir Ağları	0,74
Lojistik Regresyon	0,73
Destek Vektör Makineleri	0,73
Rassal Orman	0,72
Karar Ağacı	0,72
K-En Yakın Komşu	0,62

ROC eğrisine göre, K-En Yakın Komşu haricinde diğer algoritmaların model performans gücü nispeten birbirine yakın değerlere sahip olsa da Gradyan Artırma algoritmasının sınıflandırmadaki başarısının daha yüksek olduğu söylenebilir. Yapay Sinir Ağları ve WOE'li Lojistik Regresyon modeli benzer sınıflandırma performansı gösterirken, WOE'li Lojistik Regresyon analizine ait ROC değerinin, değişkenlerin ham haliyle gerçekleştirilen Lojistik Regresyon analizinin ROC değerine göre de daha başarılı olduğu görülmektedir. Ek olarak, Destek Vektör Makineleri ile geleneksel Lojistik Regresyon modeli birbirlerine yakın oranlarda sonuçlar üretirken, ağaç tabanlı algoritmaların (Rassal Orman, Karar Ağacı) genel sınıflandırma başarısı nispeten daha düşük kalmıştır. Özellikle Rassal Orman algoritmasının temerrüde düşmeyen müşteriler için gerçekleştirmiş olduğu sınıflandırma başarısı dikkat çekse de diğer sınıflandırma ölçülerinde ki yeteneğinin zayıf oranlarda olduğu gözlemlenmiştir

### 3. Sonuç ve Tartışma

Yapılan çalışma kapsamında, Home Credit müşterilerine ait kredi kullanım bilgilerini içeren veriler kullanılarak, veri kalitesi ve model ön işleme çalışmaları gerçekleştirilmiştir. Yeni başvuru sahiplerinin veya aktif kredilerin temerrüt risk oranını değerlendirmek amacıyla, ilgili istatistiksel ve makine öğrenmesi algoritmaları uygulanmış olup, algoritmaların iyi ve kötü müşterileri ayrıştırıcı gücünün belirlenmesi performans ölçüleriyle sağlanmıştır.

Öznitelik seçimi kapsamında istatistiksel hatalardan arınma ve sınıflandırma gücü yüksek olan değişkenlerin belirlenmesi için çeşitli değişken indirgeme tekniklerinden faydalanılmıştır. İlgili algoritmalarda girdi değişkeni olarak kullanılacak nihai özniteliklerin belirlenmesi için LASSO Regresyonu değişken indirgeme tekniği olarak kullanılmış olup, değişken seçiminde geleneksel Regresyon tekniklerinden (backward, forward, stepwise) farklı bir yol izlenmiştir. LASSO Regresyonun sahip olduğu ceza parametresi sayesinde, hedef değişken üzerindeki sınıflandırma gücü yüksek olan değişkenler modelde kalmayı başararak nihai girdi olarak belirlenmiştir.

Ek olarak, nihai değişkenlerin IGN düğümü yardımıyla elde edilen WOE'li dönüştürülmüş yapılarıyla, Scorecard düğümü üzerinden Lojistik Regresyon modeli kurulmuştur. Böylelikle değişkenlerin WOE'li yapıları üzerinden gerçekleştirilen Lojistik Regresyon modeli, sınıflandırma performansları değerlendirilecek yedi algoritmanın karşılaştırılmasında sürece dahil edilmiştir.

Ham veri kümesinin %60'ı eğitim, %20'si doğrulama ve %20'si test veri seti olacak şekilde ayrılarak, makine öğrenmesi teknikleri bu veri setleri üzerinden gerçekleştirilmiştir. Ayrıca, veri kalitesi ve değişken indirgeme çalışmalarının yaklaşık %60'ı ham veri kümesi üzerinden gerçekleştirilirken, %40'ı eğitim ve doğrulama veri kümeleri ile gerçekleştirilmiştir. Algoritmalar için optimum performans sağlayan hiperparametreler, eğitim ve doğrulama veri setleri üzerinden belirlenirken, nihai model geliştirme ve performans karşılaştırmaları test veri seti üzerinden incelenmiştir.

Yukarıdaki bulgular doğrultusunda, karmaşıklık matrisinden elde edilen doğruluk, hassasiyet, özgünlük, kesinlik ve F1 skor ölçüleri, ROC eğrisiyle birlikte incelenerek, sekiz algoritmanın makine öğrenmesi yetenekleriyle gerçekleştirdiği performansları değerlendirilmiştir. Home Credit müşterilerinin temerrüt riskini değerlendirmek için en iyi sınıflandırma başarısını her bir veri setinde sağlayan modelin, Gradyan Artırma algoritması olduğu gözlemlenmiştir. Gradyan Artırma algoritmasına alternatif olarak en yakın performans başarısı gösteren WOE'li Lojistik Regresyon ve Yapay Sinir Ağlarının kullanılması uygun olsa da modelin yorumlanabilirlik özelliği açısından WOE'li Lojistik Regresyon modeli önerilmektedir. Nitekim benzer bir çalışmada da Hamori ve arkadaşları (2018), temerrüt riski skorlanmasında Yapay Sinir Ağı, Torbalama (Bagging), Rassal Orman ve Artırma (Boosting) gibi algoritmaların yeteneklerini karşılaştırarak, Artırmanın daha iyi performans sağladığını bulmuşlardır. Ayrıca Tian ve arkadaşları (2020), Karar Ağaçlarındaki birçok zayıf öğreniciyi birleştirerek tek bir güçlü öğreniciyi elde etmek için Gradyan Artırma algoritmasından faydalanarak farklı birçok makine öğrenmesi algoritmaları ile kredi risk değerlendirmeleri gerçekleştirmiş olup Gradyan Artırıcı Karar Ağaçlarının çalışmaya konu olan diğer makine öğrenmesi algoritmalarına göre daha başarılı sonuçlar ürettiği bulgusuna ulaşmıştır. Bu çalışma da mevcut çalışmamızın bulgularını destekler niteliktedir. Altan ve Demirci (2022), kredi skorlaması üzerine yaptıkları



çalışmada Gradyan Artırma algoritmasının güçlendirilmiş tekniği (XGBoost) ile çalışmada kullanılan diğer algoritmalara göre en başarılı bulguları elde etmişlerdir. Bu sonuçlar da Boosting algoritmalarının skorlamadaki genel başarısının literatürdeki kredi risk tahminlemelerinde de en iyi performansı sağlayan algoritma olduğunu göstermektedir.

Gradyan Artırma algoritmasının performans başarısı, nihai değişkenlere ait artıklardaki örüntü bilgisini parametreleştirip, algoritmik olarak kayıp fonksiyonu optimize etmesinden kaynaklanmaktadır. Bu bağlamda, Gradyan Artırma algoritmasının çalışma kapsamındaki performansını dikkate alarak, ikili sınıflandırma problemlerini çözmek için oldukça başarılı olan XGBoost, AdaBoost ve CatBoost gibi artırma (Boosting) algoritmaları, gelecek çalışmalarda karşılaştırmaya dahil edilebilir.

## **Kaynakça**

- Altan, G., & Demirci, S. (2022). Makine Öğrenmesi ile Nakit Akış Tablosu Üzerinden Kredi Skorlaması: XGBoost Yaklaşımı. *Journal of Economic Policy Researches*, 9(2), 397-424.
- Apostolik, R., Donohue, C., & Went, P., (2009). *Foundations of Banking Risk: An Overview of Banking, Banking Risks, and Risk-Based Banking Regulation*, Hoboken, New Jersey: John Wiley & Sons, Inc.
- Barboza, F., Kimura, H., & Altman, E., (2017). Machine learning models and bankruptcy prediction, *Expert Systems with Applications* 83: 405–417.
- BDDK, (2012), “Bankaların İç Denetim ve Risk Yönetimi Sistemleri Hakkında Yönetmelik”, <https://www.resmigazete.gov.tr/eskiler/2012/06/20120628-17.htm> (Erişim Tarihi: 24 Haziran 2020).
- Bell, J., (2014), *Machine Learning Hands-On for Developers and Technical Professionals*, John Wiley & Sons, Inc., Indianapolis, Indiana.
- Bellotti, T., & Crook, J., (2009). Support Vector Machines for Credit Scoring and Discovery of Significant Features, *Expert Systems with Applications*, 3302–3308.
- Bhargava, A., (Şubat 2000). Credit Risk Management Systems in Banks, ICICI Bank, s.8., [www.garp.com/library/Meets/bhargava.pdf](http://www.garp.com/library/Meets/bhargava.pdf), (27.11.2005).
- Breiman, L., (2001). Random Forests, *Machine learning*, Kluwer Academic Publishers, 45(1), 5-32.
- BROWN, I., & MUES, C., (2012). “An experimental comparison of classification algorithms for imbalanced credit scoring data sets”, *Expert Systems with Applications* 39: 3446–3453.
- Brown, I., (2014), *Developing Credit Risk Models Using SAS Enterprise Miner™ and SAS/STAT: Theory and Applications*, Cary, NC: SAS Institute Inc.
- Demirbulut, Y., Aktaş, M., Kalıpsız, O., & Bayracı, S. (2017). İstatistiksel ve Makine Öğrenimi Yöntemleriyle Kredi Skorlama, *CEUR-WS* (s. 273-284). Antalya: Turkish National Software Engineering Symposium.
- Design I. T., Gabrys B., & Petrakieva L., (2004). Combining labelled and unlabelled data, *International Journal on Approximate Reasoning*, vol. 35, p. 251-273.
- Eğrioglu, E., Aladağ, C.H., Yolcu, U., Uslu, V.R., & Başaran, M.A., (2009). A new approach based on artificial neural networks for high order multivariate fuzzy time series, *Expert Systems with Applications*, 36(7), 10589-10594.
- Hamori, S., Kawai, M., Kume, T., Murakami, Y., & Watanabe, C., (2018). Ensemble Learning or Deep Learning? Application to Default Risk Analysis, *Journal of Risk and Financial Management* 11: 12.
- Hand, D., & Zhou, F., (2009). Evaluating models for classifying customers in retail banking collections, *Journal of the Operational Research Society*, 61, 1540–1547.
- Jorion, P., (2009). *Financial Risk Manager Handbook*, Wiley Finance Series, 5. Baskı.
- Kavcıoğlu, Ş. (2019). Kurumsal kredi skorlamasında klasik yöntemlerle yapay sinir ağı karşılaştırması, *İstanbul İktisat Dergisi - Istanbul Journal of Economics*, 69(2), 207-245.
- Lindholm, A., WAHLSTRÖM, N., Lindsten, F., & SCHÖN, T. B., (2019). Supervised Machine Learning, Version (12 May 2019), s.7 [http://www.it.uu.se/edu/course/homepage/sml/literature/lecture\\_notes.pdf](http://www.it.uu.se/edu/course/homepage/sml/literature/lecture_notes.pdf) (Erişim Tarihi: 13 Mayıs 2019).
- Mandacı P.E., (2003). Türk Bankacılık Sektörünün Taşıdığı Riskler ve Finansal Krizi Asmada Kullanılan Risk Ölçüm Teknikleri, *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, Cilt 5, Sayı:1:67-84.
- Markoff J., (2015). A Learning Advance in Artificial Intelligence Rivals Human Abilities, *New York Times*, <https://www.nytimes.com/2015/12/11/science/an-advance-in-artificial-intelligence-rivals-human-vision-abilities.html> (Erişim Tarihi: 22 Mart 2019).
- Raschka, S., (2015). *Python Machine Learning*, Packt Publishing Ltd., Birmingham, UK.
- The Royal Society, (2017). *Machine Learning: The Power And Promise Of Computers That Learn By Example*, s.16-21, [www.royalsociety.org/machine-learning](http://www.royalsociety.org/machine-learning) (Erişim Tarihi: 5 Ocak 2019).
- Tian, Z., Xiao, J., Feng, H., & Wei, Y. (2020). Credit risk assessment based on gradient boosting decision tree. *Procedia Computer Science*, 174, 150-160.
- Yeh, I. C., & Lien, C., (2009). The Comparisons of Data Mining Techniques for the Predictive Accuracy of Probability of Default of Credit Card Clients, *Expert Systems with Applications*, Vol.36, 2473-2480.
- Zhang, C., & Zhang, S., (2002). *Association Rule Mining - Models and Algorithms*, Springer, Berlin.
- Zhang, W., (2017). Machine Learning Approaches to Predicting Company Bankruptcy, *Journal of Financial Risk Management* 6: 364-374.
- Zhou, L., & Wang, H., (2012). Loan Default Prediction on Large Imbalanced Data Using Random Forests, *Telkomnika Indonesian Journal of Electrical Engineering*, Vol.10, No.6, October 2012, 1519-1525.
- Zhu, X., & Goldberg, A. B., (2009). *Introduction to Semi-Supervised Learning*, Morgan & Claypool Publishers.