

Kredi Skorunun Belirlenmesinde Yapay Sinir Ağları ve Karar Ağlarının Kullanımı: Bir Model Önerisi

Ferdi SÖNMEZ¹

Özet

Kredi riski bankacılıkta öne çıkan risklerden birisi olup bankaların karlılık oranlarını üzerinde önemli etkiye sahiptir. Buna bağlı olarak, bankalar ve diğer finans kuruluşları için tüketicilere kredi verme konusunda karar vermede yardımcı kredi skorlama sistemleri geliştirmek önem arz etmektedir. Finansal kuruluşlar, kredi/borç talep eden müşterilerine kredi kullandırma kararlarında izleyecekleri yolu belirleyebilmek için, kredi skoru üzerinde etkisinin olduğu düşünülen faktörler arası ilişkileri ortaya koyan çeşitli içsel kredi değerlendirme modellerine başvurmaktadır. Literatürde, kredi skorlaması analizlerinde istatistik ve makine öğrenme teknikleri yaygın olarak incelenmiştir. Bu çalışmada başta bankalar olmak üzere finansal kuruluşlar ve bu kuruluşların müşterileri için de önem arz eden müşteri kredi skorunun belirlenmesi konusu ele alınmaktadır. İstatistiksel teknikler ve makine öğrenme teknikleri, son yıllarda ticari kredilerindeki büyüme ile giderek daha önemli hale gelmiştir. İstatistiksel yöntemler geniş bir yelpazede uygulanmış olmasına rağmen ticari gizlilik nedeniyle literatürde sınırlı olarak yer almaktadır. Bu çalışmada, bir bankaya başvurarak kredi talep eden bireysel müşterilerin kredi talebinin kabul edilmesi ya da reddedilmesi kararının verilmesine yönelik, yapay sinir ağları (YSA) metodolojisini temel alan bir yazılım modeli önerilmektedir. Bir mevduat bankasına ait gerçek veri kümesi uygulamada kullanılmış ve sonuçları ayrıca geliştirilen karar ağacı (KA) modelinin sonuçları ile karşılaştırılmıştır. Her iki model doğrultusunda, bir bankaya gelen bireysel kredi başvurusuna yönelik verilecek nihai karar nümerik bir örnek üzerinden değerlendirilmektedir. Elde edilen bulgular, YSA modelinin müşteri kredi skorunun tespitinde yüksek öngörü doğruluğunu sağlama ve kredi riskini belirli ölçüde tahmin edebilmede KA modeline göre başarılı olduğunu göstermektedir. Bununla birlikte, geliştirilen

¹ (Yrd. Doç. Dr.) İstanbul Arel Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü
ferdisonmez@arel.edu.tr

yazılım modelinin kuruluşlara kredilerden elde ettikleri karlılık oranlarının artması hususunda da yararlı olacağı düşünülmektedir.

Anahtar Kelimeler: *Kredi riski, kredi değeri, kredi skoru, ticari banka, karar ağaçları, yapay sinir ağları*

Using Artificial Neural Networks and Decision Trees for Credit Scoring: A Model Proposal

Abstract

Credit risk is one of the major risks faced by commercial banks and has an important effect on profitability ratios. Consequently, the credit scoring system in decision making for banks and other financial institutions lending to consumers is very important. Financial institutions constitute various internal credit assessment models reveal relationships between variables affecting credit scoring. In the literature, statistics and machine learning techniques for credit ratings have been widely studied. In this study, particularly for banks, financial institutions and customers of these institutions are discussed, including issues that are important to determine customer's credit score. Customer's credit score is a term used to allocate credit using statistical techniques and methods of machine learning techniques. Such methods have become increasingly more important in recent years with the growth in commercial loans. Although a wide range of applied statistical methods included in the literature, they are limited because of commercial confidentiality. In this study, for issuing the decision on the assessment of customers' demand for credit, acceptance of loan requests or refusal, a software model based on the artificial neural network (ANN) methodology is recommended. A real data set belongs to a deposit bank was used for the application. In addition to this, this study benchmarks the performance of ANN model with decision trees (DT) model. Based on the findings, ANN model outperforms the DT model in terms of estimating credit risk and customer's credit score. It is also considered that the model would be helpful in increasing the profitability of lenders gained from credits.

Keywords: *Credit risk, credit worthiness, credit score, commercial banks, decision trees, neural networks*

1. Giriş

Kredi riskinin doğru değerlendirilmesi kredi veren kuruluşlar için son derece önem taşımaktadır. Kredi skorlama, kredi başvurusunda bulunan kişinin varsayılan finansal yükümlülüğü üzerinde tutabilme ihtimalini tahmin etmek ve kredi vermek veya vermemek yönündeki karar için finansal kurumlar tarafından gerçekleştirilen analizlere yardımcı olarak yaygın kullanıma sahip bir tekniktir (Lessman vd., 2015). Başvuru sahibinin kredi skoru veya değerliliği üzerindeki kesinlik kazanan karar olası kayıpları en aza indirerek finansal kurumların kredi verme hacmini arttırmaya yardımcı olmaktadır. Kredi hacmi son yıllarda muazzam bir büyüme yaşamıştır (Ritz, 2012). Potansiyel başvuru sayısının artması kredi onay prosedürünün otomatikleşmesini ve borçlunun finansal sağlığını denetleyen ileri tekniklerin gelişmesine yardımcı olmuştur (Giannetti vd., 2008). Kredi portföylerinin büyük hacimde oluşu ve kredi skorlamadaki doğruluk oranının artması beraberinde finansal kurumlar için önemli kazançları da getirmiştir (West, 2000).

Kredi değerliliği tahmin modelinin amacı kredi başvurusunda bulunanları iki grupta (Lessman vd., 2015) sınıflandırmaktır: yükümlü olanı geri ödeyebilecekler (iyi kredi sınıfı veya iyi performans sınıfı) ve finansal yükümlülüğünü yerine getirememeye olasılığı yüksek olması nedeniyle krediden mahrum bırakılması gerekenler (kötü kredi sınıfı veya düşük performans sınıfı). Kredi değerliliği, kredi alan kişinin yatırımcıya veya borç verene krediyi geri ödemesinin mümkün olma olasılığını ifade etmektedir. Zayıf kredi değerliliği, (Abdou, 2009; Lessman vd., 2015) bir kredi üzerinde yüksek risk olduğunu göstermekte ve böylece yüksek faize ya da kredinin reddine yol açabilmektedir.

Kredi değerliliğinin belirlenmesi çalışmalarında Çok Değişkenli Diskriminant Analizi (DA), Lojistik Regresyon (LR) gibi istatistiksel metotlar kullanılmaktadır. Veri madenciliği teknikleri ve akıllı sistemler büyük veri setlerinden gelen potansiyel ve önemli bilgileri bulmak için iyi araçlardır (Hsieh, 2004). Birçok çalışma (Landaño vd., 2007; Sheen, 2005) karar ağaçlarının ya da yapay sinir ağlarının (YSA), diskriminant analizi ya da lojistik regresyona göre kredi talep edenin iflas veya düşük performans gösterme ihtimalinin tahmininde daha tutarlı sonuçlar sergilediğini göstermiştir. Bununla birlikte bazı çalışmalarda

(Hsieh, 2004; Lee ve Chen, 2005) farklı modellerin güçlü yönlerini içeren melez metodolojiler üzerinde durulmaktadır. Bu çalışmalardan elde edilen bulgular, LR, ANOVA, DA gibi istatistiksel yöntemlerin, değişkenlerin seçiminde çok etkili iken akıllı sistemlerin hüküm sağlamada etkili olması, melez metodolojilerin en iyi performansı (Tsai ve Chen, 2010) sunduğunu göstermektedir. Literatürdeki kredi değerliğini tespiti çalışmalarında (Lee vd., 2002; Chen ve Huang, 2003; Hsieh, 2005; Abdou, 2009) istatistiksel ve akıllı teknikleri birleştiren melez metodolojilerin de denendiği görülmektedir.

Bu çalışmada iki amaç ele alınmaktadır. Çalışmanın birinci amacı, YSA'ların kredi talep edenlerin kredi skorunun belirlenmesindeki gücünü tartışmaktır. İkinci amaç, geçmiş çalışmalarda elde edilen performans ölçütlerinde daha iyi bir sonuç elde etmeyi sağlayan bir YSA metodolojisi üzerine kurulu bir yazılım modelinin geliştirilmesidir.

Bu bağlamda çalışmada çok katmanlı ağ (ÇKA) Levenberg-Marquard geriye yayılım algoritması (LM) ile kredi talep bireysel müşterinin kredi skorunu hesaplamayı amaçlayan bir yazılım modeli geliştirilmiş ve modelden elde edilen bulgular karar ağacı modelinden elde edilen bulgularla karşılaştırılmıştır. Ayrıca, değerlendirme için geliştirilen üç katmanlı YSA modeli ve karar ağacı modeli açıklanmaktadır.

2. Veri Hazırlama

Burada müşteri kredi değerliğini etkileyen, literatür çalışmalarına ve ilgili alanın uzmanlarına danışılarak belirlenen ve çalışmada kullanılan faktörler ve veri seti açıklanmaktadır.

Çalışmada bir mevduat bankasına ait bireysel tüketici kredisi başvuru verileri eğitim ve test amacıyla kullanılmıştır. Veri seti 2012-2014 dönemini içine alan ve aşağıda listelenen faktörlere ait müşteri bilgilerini içermektedir:

- Finansal Faktörler,
- Finansal Olmayan Faktörler,
- Davranışsal Faktörler,
- Makroekonomik Faktörler.

2.1. Değişkenler

Çalışmada kullanılan ve müşteri kredi değerliliği üzerinde etkisi olduğu düşünülen değişkenler aşağıda açıklanmaktadır. Bu faktörler kredi veren taraf ve alan tarafın çeşitli özelliklerini yansıtmaktadır. Bu çalışmada geleneksel bankacılıkta yapılanın aksine sayısız nitel değişken dikkate alınarak müşteri kredi değerliğinin ölçümünde daha nitel davranan bir model geliştirilmeye çalışılmıştır. Bununla birlikte literatürdeki son çalışmalarda da (Grunert vd., 2005) nitel değişkenlerin kullanımıyla birlikte modellerin tahmin gücünü arttığı ifade edilmektedir. Borçluların temerrüde düşmesi ihtimalinin genel ekonomik durum ile yakın bir ilişkide olmasından dolayı (Akkoç, 2012) belirlenen ilgili makroekonomik değişkenler de bağımsız değişken olarak dikkate alınmıştır. Bağımlı değişken olarak müşterinin borcunu ödeyememe durumunu ifade eden temerrüde düşme değişkeni kullanılmıştır. Bu değişken iki değer almakta olup, 0 en iyi kredi değerliğini (iyi performans) ve 1 temerrüde düşme (düşük performans) riskinin ifade etmektedir.

Literatürde değişkenlerin seçimi ve verilerin biçimi ile ilgili çok sayıda çalışma bulunmaktadır. Değişkenler seçilirken ilgili literatür çalışmaları (West, 2000; Grunert, 2005) ve alandaki uzmanların görüşleri dikkate alınmıştır. Araştırmacılar modelde değişkenleri seçmek için pek çok metot önermişlerdir (Haykin, 2009; Huang, 2009; Öztemel, 2012). Bununla birlikte, araştırmacılar bir modelin mükemmel olabileceğini, ancak değişkenlerin elverişsiz olduğu durumda iyi performans sonuçlarını elde etmenin çok zor olacağını ifade etmişlerdir.

Aktif Getirisi : Yüksek aktif getirisi temerrüde düşme olasılığını azaltmaya yardımcı olabilmektedir. Aktif getirisi net kar / toplam aktifler oranı ile ifade edilmektedir.

Alınan Krediler: Geçmişte müşteriye verilen kredilerin bilgisi kredi verenin müşterinin riskli ve güvenilir olduğunu gösterebilmektedir. Kredi veren müşterinin geçmişte aldığı tüm kredilere ve ödeme düzenine bakabileceği gibi son yıla ait kredi ve ödeme düzenine de bakabilir. Bu sebeple bu çalışmada alınan tüm krediler ve son yıla ait krediler değerleri kullanılmıştır.

Bölge: Gelişmiş bir bölgede yaşayan ve işletmesi gelişmiş bir bölgede bulunan kredi müşterileri genellikle kırsal alanlardakilere göre daha az mali sıkıntı riski taşımaktadır. Bölge değişkeni kukla değişken ile ifade edilecek olup 1 gelişmiş bölge ve 0 kırsal bölgeyi ifade etmektedir.

Cinsiyet : Literatürde (D’Espallier, vd.) borç ödeme konusunda kadınların erkeklerden daha düzenli olduğu gösterir çalışmaların mevcut olması cinsiyetin kredibilite üzerinde etkisi olan bir faktör olarak ele alınmış ve çalışmada kullanılmıştır. Düzensiz Ödeme: KKB kayıtları üzerinden alınacak ve müşterinin ödeme geçmişini veya kapasitesini gösteren diğer bankalardaki kredilerin ödemelerinde 2 dönem üst üste gecikme olumsuz bir kredibilite göstergesi olarak ele alınmış ve kullanılmıştır. Bununla birlikte en uzun ödemede gecikme süresi ve ortalama gecikme süresi de çalışmada olumsuz bir kredibilite göstergesi olarak ele alınmış ve kullanılmıştır.

Gelir-Gider Yapısı : Gelir – gider yapısı kredi talep edenin gelir gider göstermektedir. Bu kapsamda başvuru sahibinin başvurduğu güne kadar olan gelir / toplam aktifler ve giderler / toplam aktifler oranları çalışmada kredi değerliğini etkileyen iki faktör olarak ele alınmaktadır.

Kanuni Takip Durumu: Geçmişte herhangi bir ödeme sorunu olan ve hakkında kanuni takip durumu olan kredi talep eden ve borçluların riskli olarak değerlendirilmektedir. Bu durum olumsuz bir kredibilite göstergesi olarak ele alınmış ve kullanılmıştır. Kredi Faiz Oranı : Bir borçlanma kaynağının faiz oranı ne kadar yüksek olursa, borçlunun onu geri ödemesi daha zorlukla olmaktadır (Yazıcı, 2011). Buna bağlı olarak, faiz oranı ile alınan borcun düzenli ve kolaylıkla ödenmesi arasında negatif yönlü bir ilişki olduğu düşünülmektedir.

Kredi Notu : Bireysel kredi notu (BKN) kredi talep edenin, Kredi Kayıt Bürosu A.Ş.(KKB) üyesi olan kuruluştan alacağı krediyi geri ödemedeki risk seviyesini tahmin etmek amacıyla hesaplanan sayısal bir değerdir.

Likidite : Likidite oranındaki yüksek olması beraberinde temerrüde düşme olasılığının düşük olmasına sebep olacağından likidite kredi değerliği pozitif yönde etkileyen önemli bir faktördür.

Medeni Durum: Evli olmak beraberinde aileye sahip olmanın verdiği yaşam biçimi, yerleşik olma ve sorumluluk gibi olumlu etkilere sahip olması nedeniyle bekarlığa göre kredi değeri arttıran bir faktör olarak düşünülmektedir ve medeni durum çalışmada kullanılmıştır.

Meslek ve Kıdem : Bir firmanın işleyişinde veya yönetiminde deneyime sahip müşteriler, bu deneyime sahip olmayan diğer çalışanlara olanlara göre daha fazla kredi değerliğine sahip olarak görülmektedir. Literatürde, işsiz grubundaki müşteriler en düşük kredibiliteye sahip iken, yönetici veya firma sahibi konumunda olanlar ve mesleki kıdemi yüksek olanlar en yüksek kredibiliteye değerine sahip olduğu (Yazıcı, 2011) ifade edilmiştir. Kredibiliteyi etkileyen bu faktörler diğer önemli göstergelerle birlikte çalışmada ele alınmıştır. Buna ek olarak, son işyerinde çalışma süresi istikrar ve düzene sahip olmanın bir göstergesi olarak kredibiliteyi olumlu yönde bir faktör olarak ele alınmış ve çalışmada kullanılmıştır.

Özkaynak Getirisi: Kredi talep edenin (firma) finansal getirisinin yüksek oluşu ile temerrüde düşme olasılığı arasında negatif ilişki bulunmaktadır. Yatırımın kârlılığını gösteren özkaynak getirisi net kâr / özkaynak oranı ile ifade edilmektedir.

Red Edilen Krediler: Geçmişte kredi başvurusu red ile sonuçlanan müşterinin finansal problem yaşama riski bulunabilir. Çalışmada red cevabı alan başvurulardaki kredi miktarı değeri kullanılmıştır.

Sektör : Kredi talep edenin (firma) hizmet verdiği sektör kukla değişken ile ifade edilmiştir: tarım ve hayvancılık sektörü için 1, hizmet sektörü için 2, sanayi sektörü için 3 ve ticaret sektörü için 4.

Teminat : İtibarı borçlunun temel teminatı olarak görülmektedir. Bu nedenle kredi veren kuruluşlar ödeme yükümlülüklerini tamamıyla yerine getiren müşterilerinden herhangi bir kefil veya teminat (ipotek gibi) istemeyerek kredi sözleşmesi yapmayı yeterli bulabilmektedir. Bununla birlikte, nadiren veya sıklıkla ödeme yükümlülüklerini yerine getirme sorunları bulunan müşterilerden kefil veya ipotek gibi bir teminat sağlamaları istenebilmektedir.

Vade : Literatürde (Yazıcı, 2011) yaygın olarak uzun vadeli verilen borçların bankalara kısa vadeli borç vermeye oranla daha yüksek risk getirdiği ifade edilmektedir. Bu nedenle, vade süresi ile kredi değeri arasında negatif yönlü bir ilişki olduğu düşünülmektedir.

Yaş : Yaş ve temerrüde düşme olasılığı arasındaki ilişki hakkında hiçbir ampirik kanıt bulunmamakla birlikte yaş kredibilitiyi etkileyen bir faktör olarak çalışmada kullanılmıştır.

Yükümlülükler : Bu faktör, kredi talep edenin sahip olduğu yükümlülüklerin yüzdesini temsil etmektedir. Kredi değeri ile negatif yönde ilişkide olduğu düşünülen bu faktörde toplam borçlar / (toplam pasifler + toplam özkaynak) oranı kullanılmaktadır.

Kredi değerinin makroekonomik faktörlere de duyarlı olduğu düşünülmektedir. Makroekonomik ortam borçlunun ödeme davranışını etkileyen önemli bir faktördür (Kim ve Sohn, 2010). Makroekonomik faktörleri barındıran bağımsız değişkenler açısından literatürde, genellikle beş makroekonomik değişken kullanıldığı görülmektedir: Yıllık reel GSYİH, yıllık enflasyon oranı, faiz oranı, konjunktürel çıktı ve döviz sepeti. Bu değişkenler aşağıda tanımlanmaktadır.

Konjunktürel Çıktı : Kredi değerinin konjunktürel (döngü-yönlü) olmasının birkaç nedeni olduğu ifade edilmektedir. Birinci neden, konjunktürel düşüşlerde borç vermede azalma olurken borç almada yükselme olması ihtimalidir (Olson ve Zobuni, 2011). İkinci neden, konjunktürün yükseldiği dönemlerde kredi ve menkul kıymet işlemleri için taleplerin kuvvetlenmesi ve faiz marjının genişlemesidir. Makale kapsamında, GSYİH büyüme oranı, işsizlik oranları, döviz sepeti, sanayi üretim endeksi, hisse senedi fiyat endeksi ve para arzı değişkenleri konjunktürel dalgalanmaların temel faktörleri olan yatırımlar ve sermaye birikimleri ile ilişkili olmaları nedeni ile kullanılmaktadır.

Döviz Sepeti : Yabancı para birimi üzerinden verilecek kredi, kur riskine maruz kalmaktadır. Bununla birlikte, döviz kurunun makro ekonomiyi de etkileyen bir faktör olması nedeniyle döviz kuru (döviz sepeti) çalışmada önemli bir faktör olarak görülmektedir ve kullanılmaktadır.

Enflasyon Oranı : Enflasyon, gider ve gelirlerin reel değerini etkilemektedir. Enflasyon oranı tüm mal ve hizmetler için tüketici fiyat endeksindeki (TÜFE) genel artış oranını göstermektedir. Yüksek ve değişken enflasyon, bankaları ve finansman kuruluşlarını çeşitli finansman yatırımlarına teşvik etmekle birlikte uygulanan para politikası stratejisi doğrultusunda kredi verme davranışlarını etkileyebilmektedir.

Faiz Oranı : Bankalar tarafından mevduata uygulanan ortalama yıllık faiz oranları ile alınan borcun düzenli ve kolaylıkla ödenmesi arasında negatif yönlü bir ilişki olduğu düşünülmektedir.

Yıllık Reel GSYİH Büyüme Oranı : GSYİH bankaların faaliyet gösterdikleri ülkedeki pazarın boyutunu ölçmede kullanılan bir göstergedir. GSYİH büyüme oranının, mevduat ve kredilere olan talebi ve arzı etkileyen birçok faktör ile ilişkisi bulunmaktadır.

Yukarıdaki mikro ve makro ekonomik değişkenlere rağmen kredi değerliğinin hesaplanmasının ardından kredinin verilme kararında risk analistinin düşüncesi de büyük önem arz etmektedir. Bu karar subjektif olmakla birlikte finansal sorunu olan müşterileri ilgilendiren kararlarda önem arz etmektedir.

3. Metodoloji

Modelde veri kaynağı olarak kredi talep eden müşterinin yukarıdaki değişkenlere ait verileri Türkiye’de faaliyet gösteren XX mevduat bankasından, makroekonomik değişkenlere veriler ise Türkiye Cumhuriyet Merkez Bankası (TCMB), Türkiye Bankalar Birliği (TBB), Türkiye İstatistik Kurumu (TÜİK), Devlet Planlama Teşkilatı (DPT) web sitesi kullanılarak elde edilmiş ve her bir müşteri için YSA ve karar ağaçları metodolojisi yardımıyla kredi skoru hesaplamak amaçlanmıştır. Çalışmada kullanılan veri 2012 ile 2014 yıllarını içine alan 2 yıllık bir dönemine ait aylık verilerin çıkarılması ile elde edilmiştir.

3.1. Çapraz Doğrulama

Güvenilir bir şekilde tahmin sağlamak ve kredi skorlama modellerinin geliştirilmesindeki veri bağımlılığı etkisini en aza indirmek (Olson, Delen ve Meng, 2012) için K-kat çapraz doğrulama kullanılmaktadır. Burada,

tüm kredi veri seti K tane ayrışık ve yaklaşık olarak eşit büyüklükte alt gruplara (kat) rastgele ayrılmaktadır. Her bir katta, K bölümden biri, test bölümü olarak ayrıldıktan sonra, geriye kalan K-1 tane parça üzerinden eğitim gerçekleştirilmektedir. Eğitim bittikten sonra doğruluk performansı ayrılmış olan test parçası üzerinden hesaplanmaktadır. Bu işlem diğer parçaların da en az bir kez test veri kümesi olacağı şekilde K kere tekrarlanmaktadır. Son olarak K tane farklı doğruluk değerinin ortalaması alınmaktadır. Bu araştırmada, literatürde yaygın olarak kullanıldığı gözlemlenen (Giam ve Olden, 2015) 10 kat çapraz doğrulama kullanılmıştır. 10-kat çapraz doğrulamadan elde edilen bir tahminin, yaygın olarak tek bir doğrulama seti kullanılarak uygulanan bir tahminden daha güvenilir olacağı düşünülmektedir.

3.2. Yapay Sinir Ağları

YSA; genelleme, öğrenme, tahmin etme, özellik belirleme, ilişkilendirme, sınıflandırma, optimizasyon ve modelleme gibi geniş bir yelpazedeki amaçlara hizmet eden hesaplama modellerine sahiptir. Genelleştirme kabiliyeti YSA'nın önemli bir avantajıdır. Bu kabiliyetleri sayesinde yeni örüntüleri yüksek doğrulukla tasnif edebilmektedir (Cao, 2003). YSA'nın üstünlüklerinin yanı sıra önemli bir dezavantajı (David, 2000; Haykin, 2009; Lavanya ve Parveentaj, 2013), yorumlanmalarında sıkıntılar barındırıyor olmalarıdır. YSA ile tahmin modeli oluştururken ağ yapısındaki katman sayısı ve katmanlardaki nöron sayısı, ağ eğitim parametreleri gibi birçok parametrenin belirlenmesi gerekmektedir. Ancak, bu tür parametrelerin pek çoğu deneme yanılma yöntemi (Ravi ve Zimmermann, 2001; Haykin, 2009, Öztemel, 2012) ile belirlenmektedir. YSA'nın genelleme veya tahmin becerilerini tam anlamıyla kullanabilmeleri için çok daha büyük veri setlerine (Haykin, 2009) ihtiyaç duyulmaktadır.

İleri beslemeli ağ yapısına sahip olan ÇKA ağları, öğretmenli öğrenme stratejisini kullanmaktadır. ÇKA ağının öğrenme kuralı olan Geri Yayılım Algoritması (GYA), hata kareleri ortalamasının (HKO) minimize edilerek bağlantı ağırlıklarının yeniden ayarlanması mantığına dayanmaktadır. GYA, 'Genelleştirilmiş Delta Kuralı' olarak da adlandırılmaktadır (Haykin, 2009). YSA yapısı (Haykin, 2009), bağlantılar aracılığıyla aralarına katılan bir grup düğümleri barındırmaktadır. Çok Katmanlı Algılayıcı (ÇKA) ağında nöronlar (Haykin, 2009; Ravi ve Zimmermann, 2001) katmanlar

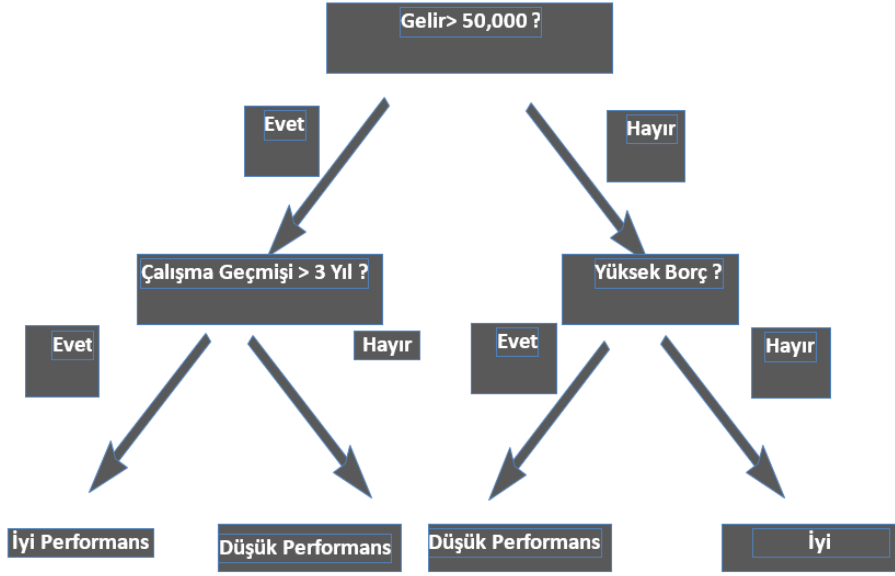
halinde organize edilmiştir. Çok Katmanlı Algılayıcı (ÇKA) YSA tahmin modellerinde sıklıkla tercih edilen algoritmalarındandır. ÇKA, regresyon problemlerinde doğrusal olmayan olayların tahmininde kullanılmaktadır (Haykin, 2009).

Bankacılık ve finans alanında büyük veri setlerini içeren uygulamalarda YSA başarı ile kullanıldığı görülmektedir (Cao, 2003; Demuth vd., 2009; Chen vd., 2013). Ancak büyük veri setleri ile uğraşmak beraberinde çok güçlü bilgisayar ve algoritmaların varlığını gerektirmektedir. Bu durum doğru modeli bulmayı güçleştirmektedir. Levenberg-Marquardt (LM) GYA, her yineleme için çok az hesaplama zamanına sahip, etkili bir öğrenme algoritmasıdır (Anyaeche ve Ighravwe, 2013; Lavanya ve Parveentaj, 2013). Bu sorunları dikkate alarak ve öne çıkan avantajlarından dolayı model belirlemek için LM algoritması kullanılmıştır. Quasi-Newton yöntemleri gibi, LM algoritması Hessen matrisi hesaplamak zorunda kalmadan ikinci derece eğitim hızına yaklaşım için tasarlanmıştır (Hagan ve Menhaj, 1994). LM algoritması verileri eğitim, doğrulama ve test olarak üç kısım halinde ele almak suretiyle ağ eğitim süresini az sayıda döngüde bitirebilmektedir. Fakat, her bir denemede aynı ağ modeli kullanılsa da farklı sonuçlar elde edilebilmektedir. LM-GYA gerçekleşen ve tahmin edilen değerler arasındaki hataları düşürmek üzerinde çalışmaktadır. Bu algoritma eğitim ve doğrulama evresindeki mutlak hatayı en aza indirmeye olanak tanımaktadır. Bu çalışmada ağın genelleme gücünü artırmak için Bayes yaklaşımı kullanılmıştır. LM optimizasyona göre ağırlık ve sapma değerlerini güncellemektedir. Böylelikle, hata kareleri ve ağırlık kombinasyonlarını en aza indirmekte (Hagan ve Menhaj, 1994) ve sonra iyi genelleştirme kabiliyetine sahip bir ağ üretmek için doğru kombinasyonu belirlemektedir.

3.3 Karar Ağaçları

Karar ağaçları geçmiş veriye dayanarak yeni verilerin hangi sınıfa ait olduğuna, kurallar çıkartarak (Rani ve Xavier, 2015) karar vermektedir. Karar ağaçlarının önemli bir avantajı üretilen karar kurallarının insanlar tarafından anlaşılmasının kolay olmasıdır. Karar ağacı, sorulan sorular ve alınan cevaplar doğrultusunda hareket etmektedir. Sorulan sorulara alınan cevapları birleştirerek kurallar oluşturulmaktadır. Öncelikli olarak (Chen, 2011; Delen, vd., 2013) soru sormaya verideki hangi değişkenden

başlanılacağına karar verilmekte ve böylelikle ilgili değişken ağacın kök düğümünü oluşturmuş olmaktadır. Kök düğümden başlayarak, cevabı veritabanında bulunan sorular sorulup alınan cevaplara göre (Chen, vd. 2014) yeni düğümler oluşturulmaktadır. Örnek bir karar ağacı Şekil 1.'de gösterilmektedir.



Şekil 1. Karar ağacında kök ve düğüm yapısı

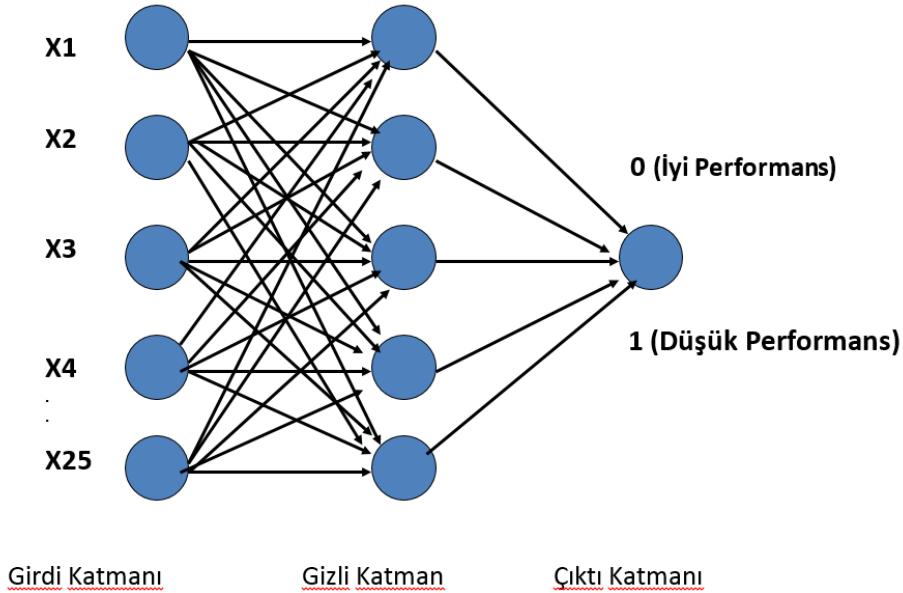
Her düğüm kendinden sonra iki dala veya ikiden fazla dala ayrılmaktadır. Oluşan düğümden sonra yeni soru sorulamıyorsa dallanma bitmiştir ve bir sınıfı temsil eden yaprağa ulaşılmıştır. Karar ağaçlarında birçok yaklaşım kullanılmakta olup C5.0 son zamanlarda (Rani ve Xavier, 2015) yaygın kullanılan ve C4.5 algoritmasının yeni versiyonu olan yaklaşım olarak ortaya çıkmaktadır.

4. Model Kurulumu ve Elde Edilen Bulgular

4.1 YSA ile Kredi Skorlama Modeli ve Sonuçları

Literatürdeki başarılı olarak ifade edilen birçok çalışma ağ yapısını ilgilendiren birçok parametrenin belirlenmesi ile ilgili standart bir yöntemin mevcut olmadığından ve parametre belirlemenin ele alınan problem ve veriye göre gerçekleştirilebileceğinden bahsetmektedir (Chen vd., 2013). Buna bağlı olarak, çalışmalarını gerçekleştiren araştırmacıların tecrübelerini

ve kazanılan diğ̈er tecrübeleri de dikkate alarak ađın en ideal sonuçları ve performansı vermesini sađlayacak parametrelerin belirlenmesi alıřmanın önemli bir bölümünü teşkil etmektedir. Ađ yapısıyla ilgili izlenen yol ve sonuçta ortaya ıkan yapı ise řöyledir. Ađın girdi katmanındaki proses elemanı sayısı girdi parametrelerinin sayısı olan 25 olarak belirlenmiştir. ıktı katmanında ise 1 adet nöron bulunmaktadır. Kurulan ađ yapısı řekil 2.'de temel nitelikleriyle gösterilmektedir. Gizli katman sayısının 1 olarak ele alınması literatür (Hippert vd., 2001; Han ve Wang, 2011) ve uzman görüşü dikkate alınarak yeterli ve uygun görülmüřtür. Ardından en iyi karşılařtırma sonucunu verecek olan ađ yapısının diğ̈er parametrelerinin belirlenmesi amacıyla ađa eđitim verisi girilerek deneme sürecine geçilmiştir. En uygun ađ modelinin belirlenmesinde verilerin ölçeklendirilmesi işleminde önemli bir husus olduđundan Matlab 2010'da bulunan mapminmax fonksiyonu yazılımının koduna eklenerek eđitim başlamadan gerçekleştirilmiştir.



řekil 2. Geliřtirilen YSA modeli yapısı

Deneme sürecinde, deđerlerine karar verilecek üç parametre ön plana çıkmaktadır: gizli katmandaki proses elemanı sayısı, öğrenme katsayısı

ve momentum katsayısı. Girdi katmanı proses elemanı sayısı n ile ifade edilirse optimal gizli katman proses elemanı sayısını bulmak için $2n$, $2n+1$, $2n+2$, $2n-1$ ve $2n-2$ değerlerine başvurulduğu görülmektedir (Öztemel, 2012; Qihong ve Jian, 2013; Sheela ve Deepa, 2013). Böylelikle, gizli katman proses elemanı sayısını belirlemek amacıyla 48, 49, 50, 51 ve 52 değerleri her 10-kat için ve öğrenme katsayısı 0,2 ve momentum katsayısı 0,6 (Öztemel, 2012) olacak şekilde test edilmiş ve performans değerleri Tablo 1’de görüldüğü üzere kaydedilmiştir (Qihong ve Jian, 2013; Sheela ve Deepa, 2013).

Tablo 1. Farklı gizli katman sayılarına göre YSA Performansı

Gizli katman proses elemanı	YSA Yapısı	Ortalama Tahmin Başarısı
28	25-48-1	62,2
29	25-49-1	65,3
30	25-50-1	64,6
31	25-51-1	63,7
32	25-52-1	64,5

En yüksek doğruluk oranı 25-49-1 ağ yapısı ile elde edilmiştir. Ardından, farklı öğrenme katsayısı (0,01–0,5) ve momentum katsayısı (0,5–0,7) değerleri için ağ ayrı ayrı çalıştırılmış, performans değerleri incelenmiş ve en iyi performansın gerçekleştiği durumdaki öğrenme katsayısı ve momentum katsayısı kaydedilmiştir.

Bu karmaşık işlemin sonunda, modelin her bir kredi talep eden müşterinin temerrüde düşme olasılığını göstermesi beklenmektedir. Aslında, gizli katmandan kullanılan logsig fonksiyonu 0 ve 1 arasında değer kümesinden oluşan çıktılar üreten bir fonksiyondur. Buradaki 0 sonucu en iyi performansa sahip müşteriyi, 1 en düşük performansa sahip, temerrüde düşme olasılığı yüksek müşteriyi işaret etmektedir.

YSA modelinin müşterileri kredi değerliğine göre ortalama doğru sınıflandırma oranı Tablo 2.’de görüldüğü üzere %65,3 olarak gerçekleşmiştir. Bu orana, parametre optimizasyonu sonucunda elde edilen

bulgular ışığında oluşturulan YSA modelinde öğrenme katsayısı 0,1 ve momentum katsayısı 0,7 olarak ayarlandığında ulaşılmıştır. Literatürdeki çalışmalara bakıldığında bu oran başarılı olarak (Akkoç, 2012) kabul edilebilir.

Tablo 2. YSA ile Kredi Değerliği Tahmin Sonuçları

Gerçekleşen (Sınıf)%	Tahmin Edilen (Sınıf)%	
	0 (İyi Performans)	1 (Düşük Performans)
0 (İyi Performans)	79,3	20,7
1 (Düşük Performans)	48,7	51,3
Ortalama doğru sınıflandırma oranı (%)	65,3	

Bununla birlikte, oluşturulan geliştirilen ağız girdi katmanında, girdi parametrelerinin sayısı kadar, yani 25 adet nöron, çıktı katmanında ise 1 adet nöron bulunmaktadır. Gizli katman sayısı 1 olup; bu katmanda 49 proses elemanı bulunmaktadır. YSA modeli iyi performansa sahip müşterilerinin %79,3'ünü ve düşük performansa sahip müşterilerin %51,3'ünü doğru sınıflandırmıştır. Buna bağlı olarak, gerçekte iyi performans sınıfında olanların %20,7'si yanlış olarak düşük performans sınıfında gözükmetedir.

Ortalama doğru sınıflandırma oranına ilave olarak modelinin başarısını ifade etmede yanlış sınıflandırmanın maliyeti de ele alınabilir. Sınıflandırma problemlerinde genellikle iki tip hata söz konusu olmaktadır: Tip I hata ve Tip II hata. Tip I hata iyi performansa sahip müşterinin düşük performans sınıfına dahil edilmesi ve Tip II hata düşük performansa sahip müşterinin iyi performans sınıfına dahil edilmesi olarak tanımlanabilir.

Tablo 3.'de YSA modelinin tarafından yapılan sınıflandırmada Tip I hatanın Tip II'den düşük olduğu (Tsai ve Chen, 2010) görülmektedir.

Tablo 3. Yanlış Sınıflandırma Oranı

Tip I hata (%)	Tip II hata (%)
20,7	48,7

Kredi değeri uygulamalarında Tip I hata ve Tip II hata arasında maliyet açısından farklılıklar (Akkoç, 2012) olduğu düşünülmektedir. Örneğin, düşük performansa sahip müşterinin doğru sınıfta tahmin edilmesi iyi performansa sahip müşterinin doğru sınıfta tahmin edilmesinden kredi riski ve karlılık göz önüne alındığında daha önem arz etmektedir. Literatürde Tip II hata ile Tip I hata arasındaki göreceli yanlış sınıflandırma maliyetinin 5 katına ulaşabildiği ifade edilmektedir (West, 2000, Akkoç, 2012).

LM GYA için uygun olarak belirtilen oranlar (Demuth vd., 2009) dikkate alınarak eğitim seti toplanan verilerin yüzde seksenini (% 80) içerirken, doğrulama ve test setlerinin her biri yüzde onunu (% 10) içermektedir. Bu oranlara, modelden alınan performans değerlerinin karşılaştırması, verinin yeniden bölünmesi denenerek ve literatürde belirtilen tecrübeler dikkate alınarak ulaşılmıştır. Elde edilen performans değeri geri bildirimlere bakılarak, çalışmada kullanılan veri setinin yüzde onluk (% 10) bir kesiti veri doğrulama amacıyla kullanılmıştır (Lavanya ve Parveentaj, 2013).

4.2 Karar Ağacı Modeli ve Sonuçları

C5.0 karar ağacı algoritması yaygın kullanıma (Chen, 2011; Delen, vd., 2013) sahip olması ve test edilmesi nedeniyle modelde kullanılmıştır. En uygun karar ağacı modelinin ortaya konulmasında diğer önemli bir husus olan verilerin ölçeklendirilmesi işlemi eğitim başlamadan gerçekleştirilmiştir. Ağacın her bir iç düğümündeki bölümleri tahmin etmede kullanılan yöntem (Rani ve Xavier, 2015) karar ağacı tahmin algoritmasının en önemli unsuru olarak ortaya çıkmaktadır. Modelde bunu gerçekleştirebilmek için C5.0 algoritması uygulamalarında sıklıkla başvurulan bir bölüm tarafından üretilen, verilerdeki entropi azalışını ölçen (Chen, vd., 2014) ve bilgi kazanç oranı olarak adlandırılan bir ölçü kullanılmıştır. Bu çerçevede, bir ağacın içindeki her düğümdeki test torun düğümlerinin entropisindeki azalmayı maksimize eden eğitim verilerinin bölünmelerine dayanarak seçilmiştir.

Bu kriterleri kullanarak, eğitim verileri kazanç oranı ağacının her düğüm noktasında maksimize olacak şekilde ardışık olarak ayrılmıştır. Her yaprak düğüm sadece tek bir sınıfın örnekler içeriyor oluncaya veya daha fazla teste rağmen bilgilerde herhangi bir kazanç elde edilemeyinceye kadar (Chen, 2011; Delen, vd., 2013) bu işlem devam ettirilmiştir. Burada, eğitim

verilerini aşırı öğrenen çok büyük ve karmaşık bir ağaç yapısı ile karşılaşma ihtimali bulunmaktadır. Bununla birlikte, eğitim setinde hataların olması ve beraberinde aşırı öğrenme veya ezberleme durumun ortaya çıkmasıyla birlikte düşük performans alınması riski de bulunmaktadır. Bu ihtimalleri göz önünde bulundurarak, sınıflandırma hatalarını azaltmak ve eğitim setinin dışındaki verilerin de sınıflandırılması amacıyla (Chen, vd., 2014) güven bazlı budama gerçekleştirilmiştir. Bir düğümdeki tüm örneklerin aynı sınıflandırılması, ağacın ilgili kısmının gelişmesini durdurmada dikkate alınmıştır.

Veri bağımlılık etkisini en aza indirmek ve sonuç tahminlerinin güvenilirliğini artırmak için, 10 kat çapraz doğrulama (Giam ve Olden, 2015) veri kümelerinden rastgele bölümler oluşturmak için kullanılmıştır. 10 rastgele bölümün her biri kalan dokuz bölüm ile eğitilmiş kredi skorlama modeli için bağımsız bir dışarıda tutma testi seti olarak kullanılmaktadır. Bağımsız dışarıda tutma testi modelin genelleme yeteneğini test etmek için kullanılır iken eğitim seti, kredi skorlama modelin parametrelerini belirlemek için kullanılmıştır.

Tablo 4'te gösterilen model performansı tüm 10 test seti bölümlerinin elde edilen sonuçların ortalamasıdır. Çapraz doğrulama kullanılarak kredi skorlama modelinin mevcut verilerin büyük bir oranı ile geliştirilmesi ve tüm verilerin modelleri test etmek için kullanılması amaçlanmıştır.

Tablo 4. Karar Ağaçları Kredi Değerliği Tahmin Sonuçları

Gerçekleşen (Sınıf)%	Tahmin Edilen (Sınıf)%	
	0 (İyi Performans)	1 (Düşük Performans)
0 (İyi Performans)	75,2	24,8
1 (Düşük Performans)	52,2	47,8
Ortalama doğru sınıflandırma oranı (%)	61,5	

C5.0 modeli iyi performansa sahip müşterilerinin %75,2'sini ve düşük performansa sahip müşterilerin %47,8'ini doğru sınıflandırmıştır. Buna bağlı olarak, gerçekte iyi performans sınıfında olanların %24,8'si yanlış olarak düşük performans sınıfında ve düşük performansa sahip müşterilerin %52,2'ini iyi performansa sınıfında gözükmemektedir.

Tablo 5. Yanlış Sınıflandırma Oranı

Tip I hata (%)	Tip II hata (%)
24,8	52,2

Tablo 5.'de C5.0 modeli ile gerçekleştirilen sınıflandırmada YSA modelinden elde edilen sonuçlara benzer şekilde Tip I hatanın Tip II'den düşük olduğu görülmektedir. Bu oran literatürdeki benzer çalışmalarda elde edilen performans oranlarına (Tsai ve Chen, 2010) yakın veya altında gerçekleşmiştir. Bununla birlikte, hata oranlarının YSA modelinden elde edilen hata oranlarından yüksek çıktığı da görülmektedir.

4. Sonuç ve Gelecek Çalışmalar

Elde ettiğimiz sonuçlar gösteriyor ki, YSA'lar genelleştirme ve sınıflandırmada iyi rol oynayan araçlardır. Bu kanıtlanmış nitelikler, YSA'ların birçok bilim dalında sorunların çözümünde kullanımını sağlamaktadır.

Bu çalışmada, YSA metodolojisini, borçlunun temerrüde düşme ve kredi skorlama kararları gibi finansal sorunların üzerine bir çözüm olarak sunmayı amaçlanmıştır. Finansal sorunlara çözüm getirmede özellikle YSA'ların genelleştirme özelliğinden faydalanılmaya çalışılmıştır. YSA metodolojisinin kullanıldığı yazılım modelinin sunduğu sonuçlar karar ağaçları metodolojisi ile geliştirilen modelden elde edilen sonuçlara göre tahminlemede daha yüksek başarı oranına sahiptir. Bu sonuca bağlı olarak, bu yazılım modelinin öncelikle ticari bankalara ve diğer finansal kuruluşlara içsel bir değerlendirme sistemi olarak ya da kredi talep eden bireysel müşterilerin borç istemeden önce değerlendirilmesi hususunda fayda sağlaması beklenmektedir.

Sonuç olarak, bu çalışmada elde edilen bulgular ışığında; geliştirilen yazılım modeli, şu anki verilerle gerçekleştirdiği kredi skorlama analizini aynı zamanda ileride ortaya çıkacak yeni verilerin modele girilmesi ile de gerçekleştirecek ve skor tahmini çalışmalarında başarılı bir araç olarak kullanılabilir. Tasarlanan yazılım modeli, kullanıcıların araştırma istekleri ve beklentilerine daha iyi cevap verebilmek için ileride daha kullanıcı dostu bir yapıya ve değişen şartlara uyum gösterme kabiliyetine

kavuşma olanağını da beraberinde getirmektedir. Buna ek olarak, ileride kümeleme analizini, lojistik regresyon, çoklu ayırma analizi ve adaptif ağ tabanlı bulanık mantık çıkarım sistemi gibi metodolojilerin kullanılması ve çalışmadaki bulgularla karşılaştırma yaparak daha yüksek başarılı bir modelin geliştirilmesi hedeflenmektedir.

KAYNAKÇA

- [1] Abdou, H.A.(2009). *Genetic programming for credit scoring: The case of Egyptian public sector banks*, Expert Systems with Applications, 36 (9), s.11402-11417.
- [2] Anyaeche, C.O. ve Ighravwe, D.E.(2013). *Predicting Performance Measures Using Linear Regression and Neural Network: A Comparison*. African Journal of Engineering Research, 1(3), s.84-89.
- [3] Cao, L.(2003). *Support Vector Machines Experts for Time Series Forecasting*. Neurocomputing, 51, s.321-329.
- [4] Chen, M-Y.(2011). *Predicting corporate financial distress based on integration of decision tree classification and logistic regression*, Expert Systems with Applications, 38(9), s.11261-11272.
- [5] Chen, M-C., Huang, S-H.(2003). *Credit scoring and rejected instances reassigning through evolutionary computation techniques*, Expert Systems with Applications, 24 (4), s.433-441.
- [6] Chen, M-Y., Fan, M-H., Chen, Y-L. and Wei, H-M.(2013). *Design of Experiments on Neural Network's Parameters Optimization for Time Series Forecasting in Stock Markets*, Neural Network World, 4(13), s.369-393.
- [7] Chen, S., Goo, Y-J.J. and Shen, Z-D.(2014). *A Hybrid Approach of Stepwise Regression, Logistic Regression, Support Vector Machine, and Decision Tree for Forecasting Fraudulent Financial Statements*, 9(16), s.1-9.

- [8] Delen, D. Kuzey, C. and Uyar, A.(2013). *Measuring firm performance using financial ratios: A decision tree approach*, Expert Systems with Applications40(10), s.3970-3983.
- [9] Demuth, H., Beale, M. and Hagan, M.(2009). *Neural Network Toolbox 6 User's Guide*. Natick, MA: The MathWorks, Inc.
- [10] D'Espallier, B., Guérin, I. and Mersland, R.(2009). *Women and Repayment in Microfinance*, Rural Microfinance and Employment, Working Paper 2009-2.
- [11] Giam, X., Olden, J.D.(2015). *A new R2-based metric to shed greater insight on variable importance in artificial neural networks*, Ecological Modelling, 313(10), s.307-313.
- [12] Giannetti, M., Burkart, M. ve Ellingsen, T.(2011). *What You Sell Is What You Lend? Explaining Trade Credit Contracts*. Rev. Financ. Stud., 24 (4), s. 1261-1298.
- [13] Hagan, M.M. ve Menhaj, M.B.(1999). *Training Feed-Forward Networks with the Marquardt Algorithm*. IEEE Transactions on Neural Networks, 6(5), s.989–991.
- [14] Han, Y. ve Wang, B.(2011). *Investigation of Listed Companies Credit Risk Assessment Based on Different Learning Schemes of BP Neural Network*. International Journal of Business and Management, 6(2), s.204-207.
- [15] Haykin, S.(2009). *Neural Networks and Learning Machine*, 3E. NJ: Pearson Education Inc.
- [16] Hippert, H.S., Pedreira, C.E. and Souza, R.C.(2001). *Neural Networks for Short-Term Load Forecasting: A Review and Evaluation*. IEEE Transactions on Power Systems, 16(1), s.44-55.
- [17] Hsieh, N-C.(2005). *Hybrid mining approach in the design of credit scoring models*, Expert Systems with Applications, 28(4), s. 655-665.

- [18] Hsieh, N-C.(2004). *An integrated data mining and behavioral scoring model for analyzing bank customers*, Expert Systems with Applications, 27 (4), s. 623-633.
- [19] Kim, H. S., & Sohn, S. Y.(2010). *Support vector machines for default prediction of SMEs based on technology credit*, European Journal of Operational Research, 201(3),s. 838–846.
- [20] Landajo M., Andrés, J., Lorca, P.(2007). *Robust neural modeling for the cross-sectional analysis of accounting information*, European Journal of Operational Research, 177 (2), s.1232-1252.
- [21] Lavanya, V. ve Parveentaj, M.(2013). *Foreign Currency Exchange Rate (FOREX) Using Neural Network*, International Journal of Science and Research, 2(10): s.174-177.
- [22] Lee, T-S., Chen, I-F.(2005). *A two-stage hybrid credit scoring model using artificial neural networks and multivariate adaptive regression splines*, Expert Systems with Applications, 28 (4), s.743-752.
- [23] Lee, T-S., Chiu, C-C., Lu, C-J., ve Chen, I-F. (2002). *Credit scoring using the hybrid neural discriminant technique*, Expert Systems with Applications, 23 (3), s.245-254.
- [24] Lessmann, S.; Baesens, B.; Seow, H-V. ve Thomas, L.C.(2015). *Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research*, European Journal of Operational Research, 247 (1), s.124-136.
- [25] Makeig, S., Jung, T.P. ve Sejnowski, T.J..(1996). *Using Feedforward Neural Networks to Monitor Alertness from Changes in EEG Correlation and Coherence*, Advances in neural information processing systems. Cambridge: MIT Press, s.931–937.
- [26] Olson, D. ve Zobuni, T.(2011). *Efficiency and Bank Profitability in MENA Countries*, Emerging Markets Review, 12, s.104-110.

- [27] Olson, D., Delen, D. and Meng, Y.(2012) *Comparative analysis of data mining methods for bankruptcy prediction*, Decision Support Systems, 52(2), s.464-473.
- [28] Öztemel, E..(2012). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık.
- [29] Rani, M.S., Xavier, S.B.(2015). *A Hybrid Intrusion Detection System Based on C5.0 Decision Tree Algorithm and One- Class SVM with CFA*, International Journal of Innovative Research in Computer and Communication Engineering, s.5526-5537.
- [30] Ravi, V. ve Zimmermann, H.J.(2001). *A Neural Network and Fuzzy Rule Base Hybrid for Pattern Classification*, Soft Computing, 5(2), s.152–159.
- [31] Ritz, R. A., (2012). *How do banks respond to increased funding uncertainty?*, Cambridge Working Papers in Economics 1213, Faculty of Economics, University of Cambridge.
- [32] Sheen, J.N.(2005). *Fuzzy financial profitability analyses of demand side management alternatives from participant perspective*, Information Sciences, 169 (3), s. 329-364.
- [33] Tsai, C-F. and Chen, M-L. (2010). *Credit rating by hybrid machine learning techniques*, Applied Soft Computing, 10, s.374-380.
- [34] Washington, S. Karlaftis, M. ve Mannering, F..(2011). *Statistical and Econometric Methods for Transportation Data Analysis - 2nd Edition*, Boca Raton, FL: Chapman and Hall/CRC.
- [35] West, D.(2000). *Neural network credit scoring models*, Computers & Operations Research 27, s.1131-1152.
- [36] Yazıcı, M.(2011). *Kredi Kartı Taleplerinin Değerlendirilmesinde Değişken Analizi*, Maliye Finans Yazıları, s.9-22.