

Firma Başarısızlığı Tahminlemesi: Makine Öğrenmesine Dayalı Bir Uygulama

T. Şükrü YAPRAKLI¹, Hamit ERDAL^{2*}

¹Atatürk Üniversitesi, İİBF, İşletme Bölümü, Erzurum, Türkiye

²Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü, Üretim Yönetimi ve Pazarlama Bilim Dalı, Erzurum, Türkiye

sukruyaprakli@atauni.edu.tr, hamit_erdal@hotmail.com

(Geliş/Received: 21.02.2015; Kabul/Accepted: 25.09.2015)

DOI: 10.17671/btd.21000

Özet— Firma risk profilinin belirlenmesi, literatürde firma başarısızlığı kavramlarıyla incelenmektedir. Bu konu üzerinde, özellikle 1929 büyük buhranı sonrasında çok önemli çalışmalar yapılmıştır. Başlarda, riskli ve başarılı firmaların finansal göstergeleri arasındaki farklılıklara yoğunlaşılırken, özellikle bilişim teknolojilerindeki gelişimlere paralel olarak son yıllarda bilişim sistemlerinden elde edilen veriler firma başarısızlığı tahminlemesinde en önemli bileşenlerinden biri olmuştur. Özellikle, makine öğrenmesi yöntemlerinin bu alanda kullanılmaya başlanmasıyla firma başarısızlığının tahmin edilmesinde önemli yol kat edilmiştir.

Bu çalışmada Erzurum ilinde 38 yıldır faaliyet gösteren inşaat malzemeleri toptancısı bir firmanın müşterilerinin vadeli borçlarını ödeme/ödememe riskleri firma başarısızlığı kapsamında ele alınmış ve firma başarısızlığının tahmininde uygun bir makine öğrenmesi yöntemi araştırılmıştır. Probleme etki eden değişkenler Temel Bileşenler Analizi (TBA) ile ortaya konulmuştur. Son yıllarda makine öğrenmesinde oldukça gelişmekte olan Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM)'nin TBA yöntemiyle beraber kullanımıyla oluşturulan hibrit modellerin bu tahminde uygulanabilirliği incelenmiş ve tahmin performansları yalın YSA ve DVM'ler ile karşılaştırılmıştır. TBA ile bütünlük olarak kullanılan hibrit modellerin tahmin başarısının yalın YSA ve DVM'lere oranla daha tatmin edici sonuçlar verdiği görülmüştür. Özellikle TBA-DVM modelinin firma başarısızlığı tahminlemesinde alternatif bir yöntem olarak etkin bir şekilde kullanılabileceği sonucuna varılmıştır.

Anahtar Kelimeler— Firma Başarısızlığı, Makine Öğrenmesi, Sınıflandırma, Temel Bileşenler Analizi, Yapay Sinir Ağları, Destek Vektör Makineleri

Firm Failure Prediction: A Case Study Based On Machine Learning

Abstract— The determination of firm risk profile is investigated in literature with the concepts of firm failure. Regarding this issue, especially after the great depression of 1929, crucial studies were performed. In the beginning, while concentrate on differences between financial indicators of risky and successful firms, the data obtained from information technologies particularly were one of the primary components of firm failure prediction in parallel with developments in information technologies. Especially, significant way on firm failure prediction has got over depending on using machine learning methods in this area.

In this study, payment/non-payment ordinary hazards about time loans of customers of a building material wholesaler firm which has been in service for 38 years in Erzurum, handled the subject within scope of firm failure and a suitable machine learning method has been investigated in firm failure prediction. The variables that have an effect on the problem was determined with Principal Components Analysis (PCA). In recent years, rather developing machine learning methods; Artificial Neural Networks (ANN) and Support Vector Machines (SVMs)'s applicabilities for the prediction, handled in this study, are being investigated with generating hybrid models by using PCA and obtained results are compared with the stand-alone ANN and DVMs. It's obtained that prediction success of hybrid methods, generated with PCA, have been found more satisfactory than stand-alone ANN and DVMs. It is concluded that especially the PCA-SVM hybrid model can be used effectively as an alternative method in firm failure prediction.

Keywords— Firm Failure, Machine Learning, Classification, Principal Components Analysis, Artificial Neural Networks, Support Vector Machines

1. GİRİŞ (INTRODUCTION)

Firma riskliliğinin incelenmesinde firmaların finansal ve operasyonel verileri, yapılacak risk analizlerinin girdisini oluşturmaktadır. Bu verilerin gerek sektör bazında bir araya getirilerek sektör eğilimleri hakkında, gerekse firma bazında incelenmesiyle firmaların olası davranışları hakkında bilgi edinmek mümkündür.

Günümüzde firmaların müşteri sayılarının hızla artmış olması bu firmaların değerlendirme sürecinde gerçekleştirilen bireysel analizlerin yerine istatistiksel ve daha ileri makine öğrenmesi yöntemleri kullanılarak daha objektif, hızlı ve tutarlı kararlar alınabildiği gözlenmiştir. Özellikle Çek Kanununda Değişiklik Yapılmasına Dair Kanun'un 03.02.2012 tarihinde yürürlüğe girmesiyle beraber karşılıksız çeke ilişkin hapis cezası kaldırılmış (madde 5), caydırıcılık vasfının azalmasıyla da firmaların müşteri değerlendirmeleri son derece önemli bir hal almıştır.

Bu çalışmada, Erzurum ilinde 38 yıldır faaliyet gösteren bir inşaat malzemeleri toptancısı firmanın müşterisi 157 firmanın verileri kullanılarak, YSA, DVM, TBA-YSA ve TBA-DVM yöntemleri ile borçlarını ödeme ve ödememe olasılıkları firma başarısızlığı kapsamında ele alınmış ve hangi müşterilere vadeli satış yapılmasına karar verilebilmesi için firma başarısızlığı tahminlemesi gerçekleştirilmiştir.

Burada dikkat edilmesi gereken en önemli konu vadeli satış yapılacak firmanın borcunu ödeyeceğinin veya ödemeyeceğinin olasılık olarak bilinmesi ve ödememe riski yüksek olan firmalara vadeli satış yapılmaması, aynı zamanda ödeme olasılığı olduğu halde vadeli satış yapmamak arasındaki dengenin doğru kurulması gerekmektedir. Birinci durum Tip-1 hata, ikinci durum ise Tip-2 hata olarak bilinmektedir. Tip-1 hatayı minimize etmek için çok keskin davranmak potansiyel müşterilere satış yapmamaya neden olacaktır. Tip-2 hatanın yüksek olması ise potansiyel olarak, kâr edilebilecek müşterilerin kaçırılmasına neden olacaktır.

Bu çalışmada; istatistik, makine öğrenmesi ve sinir ağlarından çeşitli teknikleri birleştiren DVM'ler ile insan beyninin sinir sisteminin çalışma şeklinin simüle edilmesiyle bilgi işleme fonksiyonundan esinlenerek geliştirilen YSA'ların, firma başarısızlığı tahminlemesinde kullanılabilirliği araştırılmıştır. Probleme tesir ettiği değerlendirilen faktörler için TBA analizi gerçekleştirilerek veri setinin boyutları, veri içerisinde var olan değişimler mümkün olduğunca korunarak daha az boyuta indirgenmiştir. Bu kapsamda geliştirilen TBA-YSA ve TBA-DVM hibrit modelleri ile daha fazla tatmin edici tahmin sonuçları elde edilmiş ve bu dört yöntemle elde edilen sonuçlar karşılaştırılmıştır.

Çalışmanın yöntemini oluşturan YSA ve DVM'ler el yazısı tanıma, ses tanıma, yüz tanıma, obje tanıma, bioinformatik, finansal tahmin gibi pek çok alanda başarıyla kullanılmaktadır.

2. LİTERATÜR TARAMASI (LITERATURE REVIEW)

Firmaların finansal başarısızlıklarının tahmin ihtiyacı, özellikle son yıllarda meydana gelen küresel firmaların iflası ve Basel II Anlaşmasının getirdiği kredi riskine bağlı sermaye yeterliliği ölçütüyle beraber büyük önem kazanmıştır [1].

Firma başarısızlığının tahminine yönelik çabaların uzun zamandır devam etmesine rağmen, firmaların neden başarısız olduklarına dair genel kabul gören kuramsal bir altyapı henüz oluşturulamamıştır. Wilcox [2], kuramsal çerçeve eksikliğinin, firmalarla ilgili yeterli ve doğru bilgi elde edilememesine yol açtığını ve doğal olarak doğru bir genelleme yapılamadığını öne sürmektedir. Bu kapsamda, firma başarısızlığının tahmininde kullanılacak değişkenlerin belirlenmesinde daha çok ampirik özellikler öne çıkmaktadır.

Reel sektör firmalarında başarısızlığın önceden tahmin edilmesi ihtiyacı ve başarısızlığın tahminine yönelik erken ikaz modellerinin tasarımı yolunda en erken çabalar, 1929 büyük buhranından sonra ortaya çıkmıştır. 1942 yılında Merwin tarafından başarısız firmaların finansal oranlarının başarılılardan farklı olduğunu ortaya konmuştur. 1966'da Beaver sonraki çalışmalara önemli bir temel teşkil edecek "Tek Değişkenli Analizi" geliştirmiştir. Beaver'a göre tek değişkenli analiz orta seviyede bir tahmin başarıları gösterebilmektedir. Ertesi yıl 1967'de Neter başarısızlığın tahmininde çok değişkenli bir modellemenin daha doğru sonuçlar vereceğini savunmuş ve tek değişkenli analizin firma başarısızlığının tahminine yönelik değişkenleri belirleyebildiğini fakat ilintili riski ölçmeye yönelik bir ölçek sunmadığını belirtmiştir [3].

Firma başarısızlığının modellenmesinde çığır açan ilk çalışma, Altman [4]'in Çoklu Ayırım Analizidir. Bu çalışmada kullanılan örneklemin küçüklüğü çalışmanın genellenebilirliğine gölge düşürdüğünden Altman vd. [5] tarafından daha genellenebilir bir ayırım analizi modeli olan ZETA modelini geliştirilmiştir. ZETA modeli bir çok farklı sektörden her ölçekteki firmaya uygulanabildiğinden, ayırım analizi birçok çalışmaya esin kaynağı olmuştur.

Ayırım analizi ile başlayan tahminleme çalışmaları; Meyer ve Pifer [6]'in Regresyon Analizi, Martin [7]'in Logit Regresyonu, Ohlson [8]'un Lojistik Regresyon Modeli, Zmijewski [9]'nin Probit Analizi Modeli ve West [10]'in Faktör-Lojistik Analizi gibi istatistiksel yöntemler ile devam etmiştir.

İlerleyen yıllarda bu yöntemlerin yanına karar ağaçları eklenmiş ve söz konusu istatistiksel yöntemlerden daha fazla tahmin başarısı elde edilmeye çalışılmıştır. Frydman vd. [11] başarısızlık sınıflandırmasında yinelemeli bölümlenme yöntemiyle bir ayırım ağacı geliştirmiştir. Messier ve Hansen [12] karar ağacı tekniği ile benzer bir başarısızlık tahmin modeli önermiştir.

Sınıflandırma problemlerinde makine öğrenmesi yöntemlerinin kullanılmaya başlanması ve yapay zekanın başat araştırma yöntemlerinden biri haline gelmesiyle beraber yazarlar tarafından başarısızlık tahmin modellerinde makine öğrenmesi yöntemleri etkin olarak kullanılmaya başlamıştır.

Dimitras vd. [13], 1932-1994 yılları arasında firma başarısızlığı konusunda yapılan çalışmaları taramıştır. Yazarlar firma başarısızlığı konusunda istatistiksel yöntemler arasında en fazla kullanılanların çoklu ayırım analizi (multiple discriminant analysis-MDA) ve lojistik regresyon analizi (logistic regression analysis-logit) olduğunu raporlamıştır.

Literatürde istatistiksel yöntemler arasında en fazla kullanılan bu iki yöntemin sınıflandırma başarısı olarak benzer sonuçlar sunduğu Lo [14] ve Wu vd. [15] tarafından raporlanmıştır. Hammer [16] ise LRA'nın daha az kısıtlayıcı varsayım içermesi nedeniyle üstünlüğünü, Charitou vd. [17] ise yine LRA'nın firma başarısızlığını hesaplama yeteneğinin üstünlüğünü raporlamıştır.

Literatürde yakın geçmişte ve daha kapsamlı bir tarama Ravi Kumar ve Ravi [18] tarafından yapılmıştır. Yazarlar, çalışmalarında 1968-2005 yılları arasında yapılan çalışmaları taramıştır. Çalışmalarında firma başarısızlığı tahminlemesi üzerine artık geleneksel istatistiksel yöntemlerin tek başına kullanılmadığını, araştırmacıların daha çok yeni makine öğrenmesi yöntemlerini kullanmaya başladığını raporlamıştır. Shin ve Lee [19]'de sınıflandırma problemlerinde, yeni ve parametrik olmayan yöntemlerin, özellikle YSA'ların geleneksel istatistiksel yöntemlerin yerini aldığını vurgulamıştır.

Ravi Kumar ve Ravi [18] yaptıkları literatür taramasında firma başarısızlığı literatürünü; (1) istatistiksel yöntemler ve (2) uzman sistemler olmak üzere yöntemlerine göre iki kategoriye ayırmıştır. İstatistiksel yöntemler arasında; doğrusal ayırma analizi (linear discriminant analysis-LDA), parametrik olmayan çoklu ayırım analizi (non-parametric multiple discriminate analysis-NPDA), çok değişkenli ayırım analizi (multivariate discriminate analysis-MDA), karesel ayırım analizi (quadratic discriminant analysis-QDA), logit ve faktör analizi (factor analysis-FA) yöntemlerini incelemiştir. Uzman sistemler arasında ise; yapay sinir ağları-YSA (artificial neural networks-ANN), karar ağaçları-KA (decision trees), durum tabanlı çıkarılma (case-based reasoning-CBR), evrimsel yöntemler (evolutionary approaches), kaba küme teorisi (rough set theory-RST), hibrit uzman sistemler-HUS (soft computing veya hibrid intelligent systems),

yöneylem araştırması veya doğrusal programlama (operational research techniques veya lineer programming-LP), veri zarflama analizi-VZA (data envelopment analysis-DEA), genetik algoritma-GA (genetic algorithms-GAs), gri ilişki analizi (grey relational analysis-GRA), destek vektör makineleri-DVM (support vector machines-SVMs) ve son olarak bulanık mantık (fuzzy logic-FL) yöntemlerini incelemiştir.

Literatürde firma başarısızlığı tahminleme çalışmalarında makine öğrenmesi yöntemlerinden; YSA ve DVM'lerin, doğrusal ve parametrik olmayan veri setleri ile de yüksek tahmin başarısı sundukları bilinmektedir. Bir çok çalışmada YSA (ör; [20-21])'ların ve DVM (ör; [22-24])'lerin diğer geleneksel istatistiksel yöntemler ve makine öğrenmesi yöntemlerine nazaran üstünlüğü raporlanmıştır.

Tablo 1'de firma başarısızlığı konusunda literatürde farklı yöntemlerin kullanıldığı çalışmalardan örnekler sunulmuştur.

Tablo 1. Firma başarısızlığı literatürü (literature of firm failure)

Çalışma	Örneklem Büyüklüğü	Örneklem Periyodu	Yöntem
Altman vd. [5]	111	1969-1975	ZETA
West [10]	1900	1980-1982	FA, Logit, DA+DA, LRA+LRA, GA+YSA, DA+YSA, LRA+YSA
Back vd. [25]	74	1986-1989	YSA, NPDA, Logit, DA, YSA, DA+YSA, Bulanık RST+YSA, bulanık YSA
Barniv vd. [26]	237	1980-1991	LP+DA, VZA
Ahn vd. [27]	2400	1994-1997	CBR, DA
Bian ve Mazlack [28]	37	-	LDA, Logit, YSA, bulanık mantık
Cielen vd. [29]	366	1994-1996	DVM+Logit
Yip [30]	44	1991-2001	CBR, RST, GRA
Andres vd. [31]	2836	-	Logit, YSA
Hua vd. [32]	120	1999-2004	
Lin vd. [33]	30	1999-2006	
Youn and Gu [34]	102	2000-2005	
Chaudhuri ve De [35]	50	2001-2002	Bulanık DVM, YSA
Li ve Sun [36]	135	2007-2010	CBR, DVM
Benhayoun vd. [37]	20	2009-2011	DVM
Gordini [38]	3100	-	Logit, DVM, GA
Bieliková vd. [39]	160	1993-2012	DA, Logit, KA
Xu vd. [40]	240	2000-2012	YSA, DVM, Logit

3. YÖNTEM (METHOD)

Bu bölümde, firma başarısızlığı tahminlemesinde kullanılacak TBA, YSA ve DVM'ler hakkında kısa açıklayıcı bilgiler sunulacaktır.

3.1. Temel Bileşenler Analizi (Principle Component Analysis)

TBA, bir veri setinin varyans-kovaryans yapısını, değişkenlerin doğrusal birleşimleri yardımıyla

açıklayarak, boyut indirgemesi ve yorumlanmasını sağlayan bir, çok değişkenli istatistiksel yöntemdir [41].

TBA çok sayıda birbiri ile ilişkili değişkenler içeren veri setinin boyutlarını veri içerisinde varolan değişimlerin mümkün olduğunca korunarak daha az boyuta indirgenmesini sağlar [42]. Bu yönüyle TBA verideki gerekli öznelilikleri ortaya çıkarmada oldukça etkili bir yöntemdir. Yüksek boyutlu verilerdeki genel özellikleri bularak boyut sayısının azaltılmasını ve verinin sıkıştırılmasını sağlar. Boyut azalmasıyla bazı özellikler kaybedilebilir ama amaçlanan, bu kaybolan özelliklerin veri seti hakkında çok az bilgi içeriyor olmasıdır [43]. Benzer şekilde, aykırı değerlerin varlığı, TBA yönteminin verimliliğini olumsuz yönde etkileyebileceği söylenebilir [41].

Yöntem, eldeki veriyi daha az sayıda değişkenle ifade edebilecek en iyi dönüşümü belirlemeyi amaçlar. Dönüşüm sonrasında elde edilen değişkenler ilk değişkenlerin temel bileşenleri olarak adlandırılır. İlk temel bileşen varyans değeri en büyük olandır ve diğer temel bileşenler varyans değerleri azalacak şekilde sıralanır. Gürültüye karşı düşük hassasiyet, bellek ve kapasite ihtiyaçlarının azalması, az boyutlu uzaylarda daha etkin çalışması TBA'nın temel avantajları arasında sıralanabilir [43]. TBA'nın uygulama adımları Stanimirova vd. [41] ve Sangün [44]'ün çalışmalarında kapsamlı olarak ele alınmıştır.

3.2. Yapay Sinir Ağları (Artificial Neural Networks)

YSA insan beyninin çalışma şeklinin simüle edilmesiyle bilgi işleme fonksiyonundan esinlenerek geliştirilmiştir. İlk YSA modeli 1943 yılında W. McCulloch ve W. Pitts tarafından sunulmuştur [45]. 1948 yılında Wiener "Cybernetics" isimli eserinde, sinirlerin işlevi ve çalışma prensiplerini, 1949'da ise Hebb, "Organization of Behavior" isimli eserinde öğrenme ile ilgili temel teoriyi ele almıştır. Hebb eserinde, öğrenebilen ve uyum sağlayabilen sinir ağları modeli için temel oluşturacak "Hebb Kuralı"nı ortaya koymuştur [46]. 1957 yılında ise F. Rosenblatt'ın, insan beyninin işlevlerini modelleyebilmek amacıyla geliştirdiği tek katmanlı, eğitilebilen ve tek çıkışlı bir ağ modeli olan "Perceptron"dan sonra, YSA ile yapılan çalışmalar artış göstermiştir [46].

YSA'da girdi değerleri ile çıktı değerleri arasındaki fark aşağıda sunulan hata fonksiyonu ile elde edilir [47] (d_j : hedeflenen sonuç, o_j : gerçekleşen sonuç).

$$E^p = \frac{1}{2} \sum_j (d_j^p - o_j^p)^2 \quad (1)$$

Ağırlıkları yeniden düzenlemek için hata fonksiyonunun farkı kullanılır.

$$\Delta^p w_{ji} = -\eta \cdot \left(\frac{\partial E^p}{\partial w_{ji}} \right) \quad (2)$$

Bu denklemde η sabiti (öğrenme oranı) için herhangi bir değer atanabilir. Ağırlıkların yeniden düzenlenmesi

$$w_{ij}(t+1) \cong w_{ij}(t) + \eta \cdot \delta_j \cdot i_i \quad (3)$$

şeklinde yapılır. Bu denklemde $w_{ij}(t)$: ağırlık, i_i : i düğümünün sonuç değeri olabileceği gibi, δ_j : j düğümünün hata terimi de olabilir. Bir çıkış düğümü için hata terimi (δ_j);

$$\delta_j \cong o_j \cdot (1 - o_j) \cdot (d_j - o_j) \quad (4)$$

olarak elde edilir. j düğümü bir gizli düğüm olmak üzere hata terimi ise (δ_j);

$$\delta_j \cong o_j \cdot (1 - o_j) \cdot \sum_k \delta_k \cdot w_{jk} \quad (5)$$

olarak düzenlenir. Bir "moment" teriminin (α) eklenmesi ile ağırlık değişimleri üzerine etki edilebilir.

$$w_{ij}(t+1) \cong w_{ij}(t) + \eta \cdot (d_j - o_j) \cdot i_i + \alpha \cdot (w_{ij}(t) - w_{ij}(t-1)) \quad (6)$$

3.3. Destek Vektör Makineleri (Support Vector Machines)

1960'larda Vapnik tarafından teorik temelleri atılan DVM'ler, ilk defa 1995 yılında bir sınıflandırma probleminin çözümünde kullanılmıştır. DVM'ler en basit ifadesiyle sınıflandırma (classification) ve regresyon (regression) problemlerinin analizinde kullanılan bir öğrenen makinedir [47].

DVM'ler esas olarak iki grup örneklem arasındaki mesafeyi maksimize eden optimum ayıraç hiperdüzlem (hyperplane) ile ikili (binary) sınıflandırma yaparlar. Hiperdüzlemin sınırlarına (margins) en yakın grup elemanlarına destek vektörleri (support vectors) denir [48].

DVM'ler finans ve ekonomiden [19,49] mühendislik uygulamalarına [50,51] kadar pek çok farklı alanda etkin olarak kullanılmaktadır.

İki ayrı sınıfa (gruba) ait toplam " n " sayıda elemanı olan bir eğitim kümesi Denklem (7)'de sunulmuştur [47].

$$(x_1, y_1), \dots, (x_n, y_n), \quad x_i \in \mathbb{R}^d, \quad y_i \in \{-1, +1\} \quad (7)$$

Eğitim kümesini ikili sınıflandırabilecek hiperdüzlem formülü

$$w \cdot x + b = 0 \quad (8)$$

şeklinde gösterilebilir. Hiperdüzlemin sınırları ise Denklem (9)'da ifade edildiği gibidir.

$$w \cdot x_i + b \geq 1, \quad y_i = 1 \quad (9)$$

$$w \cdot x_i + b \leq -1, \quad y_i = -1$$

Denklem (9) aşağıdaki gibi genelleştirilebilir.

$$y_i(w \cdot x_i + b) \geq 1, \quad i = 1, \dots, I \quad (10)$$

Bu denklemde w ağırlık vektörü ve b eşik değeri ifade eder. Optimal ayraç hiperdüzlemin bulunması için hiperdüzlem sınırlarının (d) maksimize edilmesi gerekir.

Bunun için w ağırlık vektörünün normu olan $\|w\|$ 'i minimize etmek için Lagrange çarpanları teoremi kullanılır.

$$d = \frac{2}{\|w\|} \quad (11)$$

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^I \alpha_i [y_i(w \cdot x + b) - 1] \quad (12)$$

Lagrange çarpanları teoremi gereği $L(w, b, \alpha)$ fonksiyonunun uç noktaları, fonksiyonun w ve b değerlerine göre türevlerinin sıfıra eşitlenmesi ile bulunur.

$$\sum_{i=1}^I \alpha_i y_i = 0 \quad \alpha_i \geq 0, \quad i = 1, \dots, I \quad (13)$$

$$w = \sum_{i=1}^I \alpha_i y_i x_i \quad \alpha_i \geq 0, \quad i = 1, \dots, I \quad (14)$$

$\alpha \neq 0$ olduğu noktalar destek vektörleridir. KKT koşulları teoremi kullanılarak Denklem (10) eşitsizliğinin $\alpha = 0$ olduğu noktalarda aşağıdaki eşitliğe dönüştürülür.

$$\alpha_i [y_i(w \cdot x_i + b) - 1] = 0, \quad i = 1, \dots, I \quad (15)$$

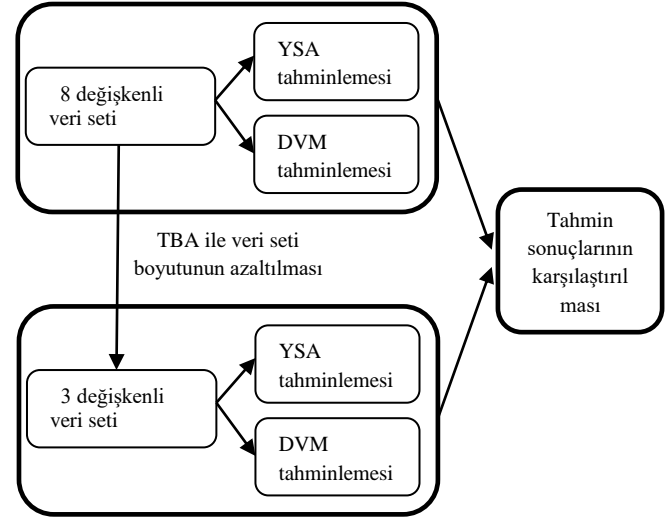
$$L(\alpha) = \sum_{i=1}^I \alpha_i - \frac{1}{2} \sum_{i=1}^I \sum_{j=1}^J \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (16)$$

Denklem (14) ve (15), Denklem (12)'de yerine konularak tekrar düzenlenirse, Denklem (16) elde edilir. $L(\alpha)$ fonksiyonu, Denklem (13)'e bağlı olarak maksimize edilerek çözüm bulunur.

İşlem yükünü azaltmak için haritalama işleminde çekirdek fonksiyonları kullanılır. Çekirdek fonksiyonu iki parametreye sahiptir. Bunlar; karmaşıklık parametresi (the complexity parameter) "C" ve çekirdeğin üstellik değeri (the exponent value) "p" dir. C ve p, DVM'lerin doğruluk oranına etki eden iki parametredir, aldıkları değerlere bağlı olarak sınıflandırma performansına etki ederler. Bu nedenle en iyi tahmin başarısını sunan C ve p parametrelerinin bulunması için çapraz-geçerlilik uygulaması yapılır.

4. VERİ SETİ VE ANALİZ (DATA SET AND ANALYSIS)

Bu bölümde, öncelikle firma başarısızlığı tahminlemesi için elde edilen veri seti tanıtılacak, daha sonra uygulanan prosedürler açıklanarak analizler gerçekleştirilecek ve elde edilen sonuçlar yorumlanacaktır. Bu çalışmada firma başarısının tahminlenmesi için önerilen metodolojinin adımları Şekil 1.'de şematik olarak sunulmuştur.



Şekil 1. Önerilen metodolojinin şematik gösterimi
(Schematic representation of the proposed methodology)

4.2. Veri Seti (Data Set)

Bu çalışmada kullanılan veri seti, Erzurum ilinde 38 senedir faaliyet yürüten bir inşaat malzemeleri toptancısı firmanın 157 müşterisinin 2006-2013 yılları arasındaki gerçek verileri ile oluşturulmuştur.

Veri seti hazırlanırken kayıp verisi olmayan 157 müşterinin verilerinden yararlanılmıştır. 157 firmanın 21'i zaman içerisinde ödeme güçlüğüne düşmüş ve borçlarını ödeyememiş müşterilerden oluşmaktadır. Literatürde genellikle, kayıp verilerden kaynaklanan problemleri gidermek için kayıp verilerin yerine değişkenlerin ortalamalarının en yakın tamsayı değerleri koyulduğu ve bu sorunun ortadan kaldırıldığı gözlenmektedir. Bu çalışmada ise tahmin başarısının hassasiyeti bakımından kayıp veriler barındıran örneklem veri setine dahil edilmemiştir.

Çalışmada firma başarısızlığının tahminine yönelik olarak başlangıçta 8 değişkenin kullanılması planlanmıştır. Bu değişkenlerin belirlenmesi sürecinde firma başarısızlığı literatüründe kullanılan değişkenlerin tarandığı Ravi Kumar ve Ravi [18]'nin çalışmasından faydalanılmıştır. Yazarlar, çalışmalarında 1968-2005 yılları arasında yapılan 62 çalışmada kullanılan değişkenleri ortayakoyuştur. Çalışmada değerlendirmeye alınması planlanan değişkenler Tablo 2'de görüldüğü gibidir.

Farklı değişkenlerin farklı kombinasyonlarının değerlendirildiği literatürdeki çalışmalar ile bizim çalışmamız arasında problemi etkileyen değişkenler bakımından farklılık oluşması doğaldır. Bu nedenle verilerin analizinde, ilk olarak, değişkenleri daha sağlıklı bir şekilde belirlemek amacıyla, veri azaltımına gitmek için TBA uygulanmasına karar verilmiştir.

Tablo 2. Değişkenler(Variables)

Değişken	Frekans	%	
Firma Sahibinin Yaşı (FSY) (Yıl)	28-37	55	35
	38-47	51	32,5
	48-57	36	22,9
	58-67	9	5,7
	68 ve üzeri	6	3,8
Firma Sahibinin Eğitim Düzeyi (FSED)	Bir okul bitirmeyen	6	3,8
	İlkokul mezunu	37	23,6
	Ortaokul mezunu	21	13,4
	Lise mezunu	43	27,4
	Yüksek öğretim mezunu	50	31,8
Firma Sahibinin Memleketi (FSM)	Erzurumlu değil	39	24,8
	Erzurumlu	118	75,2
Firma Yaşı (FY) (Yıl)	6 ve daha az	52	33,1
	7-12	63	40,1
	13-18	25	15,9
	19-24	10	6,4
	25 ve üzeri	7	4,5
Sipariş Sıklığı (SS) (Adet/Yıl)	8 ve daha az	33	21
	9-16	87	55,4
	17-24	31	19,7
	25-32	5	3,2
	33 ve üzeri	1	0,6
Ortalama Sipariş Tutarı Aralığı (OST) (TL)	999 ve daha az	5	3,2
	1.000-4.999	44	28
	5.000-9.999	21	13,4
	10.000-14.999	38	24,2
	15.000 ve üzeri	49	31,2
Toplam Borç Aralığı (TBA) (TL)	19.999 ve daha az	45	28,7
	20.000-39.999	58	36,9
	40.000-59.999	24	15,3
	60.000-79.999	17	10,8
	80.000 ve üzeri	13	8,3
Vadesi Geçen Toplam Borç Aralığı (VTBA) (TL)	999 ve daha az	119	75,8
	1.000-4.999	22	14
	5.000-9.999	2	1,3
	10.000-14.999	7	4,5
	15.000 ve üzeri	7	4,5
Firma Başarısı (B)	Başarısız	21	13,4
	Başarılı	136	86,6

Veri setinin TBA için uygun olduğuna KMO örneklemeye yeterliliği (0,657) ve Barlett's küresellik testleri ($k^2=394,869$ ve $p=0.000$) sonucunda karar verilmiştir. Bu çalışmada TBA, açık kaynak kodlu WEKA 3.7.7. yazılımıyla uygulanmıştır. WEKA yazılımı ile öncelikle

değişkenlerin belirlenmesi için kullanılan özdeğerler (eigen value), varyans %'si (açıklama oranı) ve birikimli varyans %'si değerleri hesaplanmıştır. Hesaplama sonuçları Tablo 3.'te sunulmuştur.

Analiz çıktıları incelendiğinde 8 temel bileşenden sadece 3'ünün özdeğeri 1'den büyüktür. Özdeğeri 1'den büyük olan temel bileşenler, verinin temel boyutlarını ortaya çıkarmak için yeterli olduklarından, veriyi açıklayacak oranda bilgi içermektedirler. Bu 3 faktörün tümü toplam varyansın % 65,880'ini açıklamaktadır. Birinci temel bileşen toplam değişkenliğin % 32.620'sini, ikinci temel bileşen % 20.424'ünü, üçüncü temel bileşen ise % 12.836'sını açıklamaktadır.

Tablo 3. Analiz sonuçları (Analysis results)

Faktör No.	Özdeğer	Varyans %'si	Birikimli Varyans %'si
1	2,610	32,620	32,620
2	1,634	20,424	53,044
3	1,027	12,836	65,880
4	0,967	12,089	77,969
5	0,711	8,884	86,852
6	0,500	6,244	93,097
7	0,438	5,479	98,576
8	0,114	1,424	100,000

Bu 3 temel bileşenin; yüksek açıklama oranlarıyla beraber, her bir değişkenin bu bileşenlerde aldıkları ağırlıklar dikkate alındığında, firma başarısızlığının tahmininde varsaydığımız faktörleri temsil edebileceği görülmüştür. Bu nedenle çalışmanın bundan sonraki aşamasında uygulaması gerçekleştirilecek TBA-YSA ve TBA-DVM hibrit yöntemlerinde "Firma Yaşı", "Vadesi Geçen Toplam Borç Aralığı" ve "Ortalama Sipariş Tutarı" değişkenleri esas alınarak tahminleme gerçekleştirilecektir.

Bu aşamada belirtilmesi gereken diğer bir husus da temel bileşen yükleri matrisinin sadece değişkenlerin temel bileşenlerdeki ağırlıklarını vermekle kalmadığı, aynı zamanda bu ağırlıkların yönünü de belirtebildiğidir. Temel bileşen yükü negatif değer almış ise, zıt yönde bir ilişki; pozitif değer almış ise, aynı yönde bir ilişki mevcuttur. Buna göre birinci temel bileşende firma başarısızlığına pozitif yönde katkısı en fazla olan değişken "Firma Sahibinin Eğitim Durumu", negatif yönde en fazla katkı sağlayan değişken ise "Firma Sahibinin Yaşı" değişkenidir. İkinci temel bileşende ise pozitif yönde en fazla katkı sağlayan değişken "Toplam Borç Aralığı", negatif yönde en fazla katkı sağlayan değişken ise "Firma Sahibinin Eğitim Durumu" değişkenidir. Üçüncü temel bileşende ise sırasıyla, "Firma Sahibinin Yaşı" ve "Firma Sahibinin Eğitim Durumu" değişkenleridir.

4.2. Analiz(Analysis)

Bu çalışmada YSA ve DVM yöntemleriyle yapılan tahminlemeler açık kaynak kodlu WEKA 3.7.7. programı

ile gerçekleştirilmiştir. Gerek YSA, gerekse DVM yöntemlerinde eğitim ve test aşamaları için çapraz-geçerlilik (cross-validation) yöntemi kullanılmıştır. Yöntem gereği veri kümesi “k” adet alt kümeye rassal olarak bölünmekte ve “k-1” adet kümede eğitim yapıldıktan sonra kalan kümede test yapılmaktadır. Bu işlem en iyi sonucun bulunması için bütün alt kümeler için yapılmaktadır. Çapraz geçerlilik yönteminin seçilmesindeki en önemli sebep veri kümesinin tamamının rassal olarak dağıtılıp, yeni alt kümeler oluşturularak ekstremum noktalarına takılmaktan kurtulmakta gösterdiği başarıdır. Bu çalışmada çapraz-geçerlilik yöntemi kullanarak 2 model oluşturulmuştur (Model-1: Çapraz-geçerlilik için alt küme sayısı “k=10”; Model-2: Çapraz-geçerlilik için alt küme sayısı “k=20”).

Bir çok YSA tipi bulunmakla birlikte, en çok kullanılan sinir ağı yapısı, çok katmanlı ileri beslemeli geri yayımlı YSA’dır [52]. Vellido vd. [53] YSA literatürünü taradıkları çalışmalarında, işletme ve finans uygulamalarının (halka açılma, portföy yönetimi, hisse senedi piyasalarını tahmini, kredi değerlendirmesi) %75’inde geri yayılım (back propagation) algoritmasının kullanıldığını belirtmiştir. Bu çalışmada da benzer şekilde YSA modeli olarak, çok katmanlı ileri beslemeli geri yayımlı YSA kullanılmıştır.

Ağ, üç nörondan oluşan bir girdi katmanına, üç nörondan oluşan bir gizli katmana ve tek nörondan oluşan bir çıktı katmanına sahiptir. Girdi katmanında hiperbolik tanjant, gizli katmanda ise softmaks fonksiyonu, aktivasyon fonksiyonu olarak kullanılmıştır. Ağın girdi katmanı önceki bölümde elde edilen üç faktörden, çıktısı ise firmanın başarılı olup olmadığını gösteren ikili değişkenden oluşmaktadır.

Geliştirilen YSA modelleri için iterasyon sayısı 2.000 olarak sabit tutularak, farklı öğrenme oranları ve farklı moment değerleri ile geliştirilen modellerin performansları ölçülmüştür. YSA yöntemiyle en iyi sonucu ortaya çıkaracak parametrelerin (h , α ve η) seçilmesi için sırasıyla η ve α için 0.2, 0.3 ve 0.4; h için 1, 2, 3, 4, 5, 10 ve 15 denenmiş, en iyi tahmin başarısı $\eta=0.2$, $\alpha=0.2$ ve $h=1$ değerleri ile sağlanmıştır.

DVM modelleri için de öncelikle, en iyi sonucu ortaya çıkaracak parametreler (çekirdek fonksiyonu, C ve p) seçilmiştir. Bu kapsamda; DVM’nin çekirdek fonksiyonu için polinom, radyal tabanlı fonksiyon, pearson VII (PUK) ve normalleştirilmiş polinom çekirdek fonksiyonları sırasıyla denenmiştir. Her bir model için birçok farklı denemeden sonra, DVM için normalleştirilmiş polinom çekirdek fonksiyonu seçilmiş ve parametrelerin optimizasyonu için çapraz-geçerlilik yöntemi uygulanmıştır. Normalleştirilmiş polinom fonksiyonu, veri setinin normalleştirilmesi yerine polinom çekirdek fonksiyonuna ait matematiksel ifadenin normalleştirilmesi amacıyla Graf ve Borer [54] tarafından önerilmiştir. Normalleştirilmiş polinom çekirdek fonksiyonu, polinom çekirdek fonksiyonunun genelleştirilmiş bir hali olduğu söylenebilir. Seçilen

çekirdek fonksiyonu için en uygun parametre yukarıda da belirtildiği gibi çapraz-geçerlilik yaklaşımı ile gerçekleştirilmiştir. Bunu sonucunda; p değeri için 2.0, karmaşıklık katsayısı C için de 2.0 değeri en yüksek doğruluğu sağlamıştır. Çekirdeğin üstellik değeri (p) artırıldığında, DVM modelinin karmaşık hale gelmesi neticesinde sınıflandırma işleminin önemli derecede uzadığı ve sınıflandırma doğruluğunun negatif yönde etkilendiği gözlenmiştir.

Yapılan tahminlerin başarı kriteri olarak doğru sınıflama oranı (DSO), Tip-1 ve Tip-2 hata, ortalama mutlak hata (mean absolute error-MAE), ortalama hata karekök (root mean squared error-RMSE), bağıl mutlak hata (relative absolute error-RAE) ve bağıl hata karekök (relative squared root error-RSE) esas alınmıştır.

5. BULGULAR (RESULTS)

Bu çalışmada firma başarısızlığı tahminlemesi için uygun bir makine öğrenmesi yöntemi araştırılmıştır. Bu kapsamda öncelikle Model-1 ve Model-2 için yalnız YSA ve DVM yöntemlerinin tahmin başarısı değerlendirilmiştir. Her ne kadar yalnız modeller ile tahmin başarıları için tatmin edici sonuçlar elde edilmiş olsa da daha iyi sonuçlar elde edilememesinin veri boyutundan kaynaklandığı değerlendirilmiş, veri seti boyutunun azaltılması ve tahmin performansının artırılması için ise TBA uygulanmıştır. TBA kullanılarak oluşturulan hibrit modellerin tahmin başarısını artırdığı gözlenmiştir. Benzer şekilde Model-1 ve Model-2 için hibrit modellerin performansları da karşılaştırılmıştır.

Bu çalışmada kullanılan yöntemlerin tahmin başarısı DSO, Tip-1 ve Tip-2 hata oranları kullanılarak karşılaştırılmıştır. Ayrıca kullanılan yöntemlerin performanslarını ölçmek için hata kavramını temel alan ve yaygın olarak kullanılan MAE, RMSE, RAE ve RSE ölçütleri de sunulmuştur. Böylece doğru tahmin oranı aynı olsa bile yöntemlerin birbirleriyle karşılaştırılabilmesi sağlanmıştır. Modelin, firmaları gerçekteki durumlarına göre (başarılı-başarısız) doğru şekilde bulması doğru sınıflama (DS) olarak nitelendirilir. Bu durumdaki firma sayısının toplam firma sayısına bölünmesi doğru sınıflama oranını (DSO) vermektedir. Bir firma gerçekte borcunu ödemişken modelin onu ödemeyecekmiş gibi tahmin etmesi bir hatadır. Bu durumdaki firma sayısının borcunu ödemiş firma sayısına oranı Tip-1 hata olarak nitelendirilir. Benzer şekilde borcunu ödememiş bir firmanın borcunu ödeyecekmiş gibi tahmin edilmesi ise başka bir hatadır. Bu durumda olan firma sayısının borcunu ödememiş firma sayısına oranı ise Tip-2 hatayı verecektir.

MAE, ölçüm değerleri ile model tahminleri arasındaki mutlak hatayı sorgular. MAE değeri ne kadar sıfıra yaklaşırsa, modelinin tahmin yeteneğinin o kadar iyi olduğu sonucu çıkar [55].

$$MAE = \frac{1}{N} \sum_{i=1}^N |o_i - t_i| \quad (17)$$

RMSE, ölçüm değerleri ile model tahminleri arasındaki hata oranını belirlemek amacıyla kullanılmaktadır. RMSE değerinin sıfıra yaklaşması modelin tahmin kabiliyetinin artması anlamına gelmektedir [55].

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (o_i - t_i)^2}{N}} \quad (18)$$

RAE ölçüm değerleri ile model tahminleri arasındaki göreceli mutlak hatayı yüzdesel olarak sorgular. RAE değeri ne kadar % sıfıra yaklaşırsa, modelinin tahmin yeteneğinin o kadar iyi olduğu sonucu çıkar [55].

$$RAE(\%) = \frac{\sum_{i=1}^N \left| \frac{o_i - t_i}{o_i} \right|}{N} \times 100 \quad (19)$$

RSE ölçüm değerleri ile model tahminleri arasındaki göreceli hata oranını belirlemek amacıyla kullanılmaktadır. RMSE değerinin % sıfıra yaklaşması modelin tahmin kabiliyetinin artması anlamına gelmektedir [55].

$$RSE(\%) = \sum_{i=1}^N \left(\frac{o_i - t_i}{o_i} \right)^2 \times 100 \quad (20)$$

Bu çalışmada DSO, Tip-1 ve Tip-2 hata, MAE, RMSE, RAE ve RSE ölçütleri dikkate alınarak DVM, YSA, TBA-YSA ve TBA-DVM yöntemlerinin tahmin başarıları karşılaştırılmıştır. İstatistiksel ölçütlerin hesaplanan değerleri Tablo 4'te sunulmuştur.

Tablo 4. Analiz sonuçlarının karşılaştırılması
(Comparison of the analysis results)

Yöntem	Model	DS	DSO (%)	MAE	RMS E	RAE (%)	RSE (%)
YSA	Model -1	150	95.5 4	0.04 72	0.188 0	20.05 22	55,206 1
	Model -1	151	96.1 8	0.03 82	0.174 5	16.19 45	53,455 8
TBA-YSA	Model -1	151	96.1 8	0.04 43	0.187 9	18.78 83	55,179 7
	Model -1	152	96.8 2	0.03 18	0.172 8	13.49 54	52,402 9
YSA	Model -2	151	96.1 8	0.04 00	0.172 4	16.98 68	50,624 7
	Model -2	152	96.8 2	0.03 46	0.178 5	16.19 45	53,405 4
TBA-YSA	Model -2	152	96.8 2	0.03 68	0.174 8	15.63 56	51,273 9
	Model -2	153	97.4 5	0.02 55	0.159 6	10.81 61	46,870 6

Aşağıda Tablo 5'te ise yöntemler ile modellerin Tip-1 ve Tip-2 hata oranları, sınıflandırma özet matrisinde sunulmuştur.

Tablo 4 ve 5'e göre tahmin başarıları en yüksek yöntem TBA-DVM hibriti, model ise Model-2 olarak belirlenmiştir. TBA-DVM hibrit yöntemi ile 136 başarılı firmanın 136'sı da doğru şekilde sınıflandırılmış ve doğru sınıflama yüzdesi % 100 olarak gerçekleşmiştir. Diğer yandan 21 başarısız firmanın 17'si doğru biçimde sınıflandırılmış ve doğru sınıflama yüzdesi % 80.85 olarak gerçekleşmiştir. Bu yöntem için toplam sınıflandırma başarıları düzeyi % 97.45 olarak saptanmıştır. Aynı şekilde Tip-1 hata % 0 ve Tip-2 hata da % 19.05 olarak belirlenmiştir.

Tablo 5. Sınıflandırma özet matrisi
(Classification summary matrix)

Yöntem	Model	Gözlem	Firma sayısı	Tahmin sonucu	
YSA	M-1	Başarısız	21	Başarısız 19	Başarılı 2
		Başarılı	136	%90.48	%9,52 (Tip-2 hata)
	Başarısız	21	5	131	
	Başarılı	136	%3,68 (Tip-1 hata)	%96.32	
	M-2	Başarısız	21	19	2
		Başarılı	136	%90.48	%9,52
DVM	M-1	Başarısız	21	16	5
		Başarılı	136	%76.19	%23.81
	Başarısız	21	1	135	
	Başarılı	136	%0.74	%99.26	
	M-2	Başarısız	21	16	5
		Başarılı	136	%76.19	%23.81
TBA-YSA	M-1	Başarısız	21	0	136
		Başarılı	136	%0	%100
	Başarısız	21	19	2	
	Başarılı	136	%90.48	%9,52	
	M-2	Başarısız	21	4	132
		Başarılı	136	%3,04	%96.96
TBA-DVM	M-1	Başarısız	21	17	4
		Başarılı	136	%80.85	%19.05
	Başarısız	21	1	135	
	Başarılı	136	%0.74	%99.26	
	M-2	Başarısız	21	17	4
		Başarılı	136	%80.85	%19.05
				0	136
				%0	%100

Model-1 için en düşük Tip-1 hata oranı DVM ve TBA-DVM yöntemleri ile en düşük Tip-2 hata oranı ise YSA ve TBA-YSA yöntemleri ile elde edilmiştir. Model-2 için ise yine en düşük Tip-1 hata oranı DVM ve TBA-DVM yöntemleri ile en düşük Tip-2 hata oranı ise YSA ve TBA-YSA yöntemleri ile elde edilmiştir.

Model-1 ve Model-2 sonuçlarına göre hibrit modeller ile yalın modellere göre daha iyi sonuçlar elde edilmiş, benzer şekilde dört farklı tahmin yöntemi içinde Model-2

ile daha iyi sonuçlar elde edilmiştir. Yalın YSA ve DVM'ler model performanslarına göre karşılaştırıldığında hem Model-1, hem de Model-2 için DVM'lerin daha tatmin edici tahmin sonuçları sunduğu, hibrit yöntemler içinde benzer şekilde hem Model-1, hem de Model-2 için TBA-DVM hibrit yönteminin daha tatmin edici tahmin sonuçları sunduğu görülmüştür.

6. SONUÇ VE TARTIŞMA (CONCLUSION AND DISCUSSION)

Bu çalışmada Erzurum ilinde 38 yıldır faaliyet gösteren inşaat malzemeleri toptancısı bir firmanın müşterilerinin vadeli borçlarını ödeme/ödememe riskleri firma başarısızlığı kapsamında ele alınmış ve firma başarısızlığının tahmininde uygun bir makine öğrenmesi yöntemi araştırılmıştır.

Yalın YSA ve DVM yöntemleri ile gerçekleştirilen tahminlemelerde firma başarısızlığına etki eden 8 farklı değişken ve verinin eğitim ile test verisi olarak ayrılması için 2 farklı model kullanılmıştır. Yalın YSA ve DVM'ler, model performanslarına göre karşılaştırıldığında hem Model-1, hem de Model-2 için DVM'lerden daha tatmin edici tahmin sonuçları elde edilmiştir.

Hibrit yöntemler içinse firma başarısızlığına etki eden değişkenlerin belirlenmesi ve veri setinin boyutunun ve gürültünün azaltılması için TBA ile değişken sayısı 3'e indirgenmiştir. Benzer şekilde karşılaştırma yapabilmek amacıyla bu değişkenler ile de verinin eğitim ve test verisi olarak ayrılması için aynı 2 farklı model kullanılmıştır. Model-1 ve Model-2 sonuçlarına göre hibrit modeller ile yalın modellere göre daha iyi sonuçlar elde edilmiştir. Bu sayede hibrit yöntemlerin tahmin başarısını artırdığı tespit edilmiştir. Hibrit yöntemlerin model performanslarına göre karşılaştırıldığında ise yine hem Model-1 hem de Model-2 için TBA-DVM hibrit yöntemi ile daha tatmin edici tahmin sonuçları elde edilmiştir.

Sonuç olarak, TBA ile bütünleşik olarak kullanılan hibrit modellerin, yalın YSA ve DVM'lere göre üstünlüğü ortaya koyularak; söz konusu yöntemlerin genelde çok boyutlu doğrusal olmayan tahmin problemlerinde, özelden ise firma başarısızlığı tahminlemede başarılı birer yöntem olduğu tespit edilmiştir. Bu çalışmada kullanılan veri seti özelinde ise TBA-DVM hibrit yönteminin firma başarısızlığı tahminlemede alternatif bir yöntem olarak etkin bir şekilde kullanılabileceği sonucuna varılmıştır.

Literatürde firma başarısızlığı tahminlemesi için farklı istatistiksel ve makine öğrenmesine dayalı yöntemler kullanılmıştır. Kullanılan bu yöntem ve algoritmaların hangisinin daha üstün olduğu üzerine pek çok çalışma yapılmış, yapılan bu çalışmalarda farklı veya benzer sonuçlar elde edilmiştir. Bunun en önemli nedeni tahmin başarısının, kullanılan veri setine, veri üzerinde yapılan işlemlere ve algoritma parametrelerinin seçimine bağlı olmasıdır. Farklı yazarlar tarafından, farklı veya aynı veri

setleri üzerinde, farklı parametrelerle yapılan çalışmalarda farklı veya benzer sonuçlar oluşması doğaldır. Bu çalışmada literatürde yapılan önceki pek çok çalışmanın [56-59] sonuçlarına benzer şekilde DVM yönteminin üstünlüğü tespit edilmiştir. Benzer şekilde literatürde [60-62], bu çalışmada olduğu gibi önışlem sürecinde TBA'nin kullanılması sonucunda tahmin başarısında artış gözlenmiştir.

Literatürde firma başarısızlığı üzerine yapılan çalışmaların birçoğunda klasik istatistiksel yöntemler ve makine öğrenmesi yöntemlerinden YSA'nın kullanıldığı düşünüldüğünde, bu çalışmada uygulanan DVM yönteminin ve TBA-DVM hibrit yaklaşımının alternatif birer yöntem olarak kullanılmasının sağlayabileceği faydalar ortaya konulmuştur.

Literatürde firma başarısızlığının tahminlenmesi için tahmin performansının ölçülmesinde genelde doğru sınıflandırma veya ortalama sınıflandırma performansları incelenmiştir. Bu çalışmada ise başta DSO, Tip-1 ve Tip-2 hatalar olmak üzere MAE, RMSE, RAE ve RSE ölçütleri de dikkate alınmıştır.

Benzer şekilde literatürde pek çok çalışmada veri setinin boyutlarının azaltılması için doğrusal azaltma yöntemleri kullanılmıştır. Az sayıda çalışmada ise bu çalışmada olduğu gibi doğrusal olmayan veri azaltımı yöntemleri (TBA, ISOMAP vb.)'nden TBA yöntemi kullanılmıştır.

Her çalışmada olduğu gibi bu çalışmada belirli kısıtlar altında ortaya konulmuştur. İleride yapılacak çalışmalarda algoritmaların hızı ve hafıza kullanım oranları da karşılaştırılarak algoritmaların performansları da karşılaştırılabilir. Yine, farklı tahminleme yöntem ve algoritmaları da kullanılarak sonuçlar karşılaştırılabilir.

KAYNAKLAR (REFERENCES)

- [1] E.I. Altman, "Corporate Distress Prediction Models in Turbulent Economic and Basel II Environment", <http://pages.stern.nyu.edu/~ealtman/Corp-Distress.pdf>, 2002.
- [2] J. Wilcox, "A prediction of business failure using accounting data", **Empirical Research in Accounting**, 2, 163-179, 1973.
- [3] T. Sung, N. Chang, ve G. Lee, "Dynamics of modeling in data mining: Interpretive approach to bankruptcy prediction", **Journal of Management Information Systems**, 16(1), 63-85, 1999.
- [4] E.I. Altman, "Financial ratios, discriminant analysis and the prediction of corporate bankruptcy", **Journal of Finance**, 23(3), 589-609, 1968.
- [5] E.I. Altman, R. Haldeman ve P. Narayanan, "ZETA analysis: A new model to identify bankruptcy risk of corporations", **Journal of Banking and Finance**, 1(1), 29-54, 1977.
- [6] P.A. Meyer ve H.W. Pifer, "Prediction of bank failures", **The Journal of Finance**, 25(4), 853-68, 1970.
- [7] D. Martin, "Early warning of bank failure: A logit regression approach", **Journal of banking and finance**, 1(3), 249-276, 1977.

- [8] J. Ohlson, "Financial ratios and the probabilistic prediction of bankruptcy", **Journal of Accounting Research**, 18(1), 109-131, 1980.
- [9] M.E. Zmijewski, "Methodological issues related to the estimation of financial distress prediction models", **Journal of Accounting Research**, 59-82, 1984.
- [10] R.C. West, "A factor analytic approach to bank condition", **Journal of Banking and Finance**, 9, 253-266, 1985.
- [11] H. Frydman, E.I. Altman ve D. Kao, "Introducing recursive partitioning for financial classification: The case of financial distress", **Journal of Finance**, 40(1), 269-291, 1985.
- [12] W.F. Messier. ve J. Hansen, "Inducing rules for expert system development: An example using default and bankruptcy data", **Management Science**, 34(12), 1403-1415, 1988.
- [13] A.I. Dimitras, S.H. Zanakis ve C. Zopounidis, "A survey of business failures with an emphasis on prediction methods and industrial applications", **European Journal of Operational Research**, 90(3), 487-513, 1996.
- [14] A.W. Lo, "Logit versus discriminant analysis: a specification test and application to corporate bankruptcies", **Journal of Econometrics**, 31(2), 151-178, 1986.
15. W. Wu, V.C.S. Lee ve T.Y. Tan, "Data preprocessing and data parsimony in corporate failure forecast models: evidence from Australian materials industry", **Accounting and Finance**, 46(2), 327-345, 2006.
- [16] M.M. Hamer, "Failure prediction: sensitivity of classification accuracy to alternative statistical methods and variable sets", **Journal of Accounting and Public Policy**, 2, 289-307, 1983.
- [17] A. Charitou, E. Neophytou ve C. Charalambous, "Predicting corporate failure: empirical evidence for the UK", **European Accounting Review**, 13(3), 465-497, 2004.
- [18] P. Ravi Kumar ve V. Ravi "Bankruptcy prediction in banks and firms via statistical and intelligent techniques—A review", **European Journal of Operational Research**, 180(1), 1-28, 2007.
- [19] K.S. Shin, T.S. Lee ve H.J. Kim, "An application of support vector machines in bankruptcy prediction model", **Expert Systems with Applications**, 28(1), 127-135, 2005.
- [20] G.P. Zhang, M.Y. Hu, E.B. Patuwo ve D.C. Indro, "Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis", **European Journal of Operational Research**, 116(1), 16-32, 1999.
- [21] F. Ciampi ve N. Gordini, "Small enterprise default prediction modeling through artificial neural networks: An empirical analysis of Italian small enterprises", **Journal of Small Business Management**, 51(1), 23-45, 2013a.
- [22] S.H. Min ve J. Lee, "Bankruptcy prediction using support vector machine (SVM) with optimal choice of kernel function parameters", **Expert System with Applications**, 28, 603-614, 2005.
- [23] S.H. Min, J. Lee ve I. Han, "Hybrid genetic algorithms and support vector machines for bankruptcy prediction", **Expert System with Applications**, 31, 652-660, 2006.
- [24] H.S. Kim ve S.Y. Sohn, "Support vector machines for default prediction of SMEs based on technology credit", **European Journal of Operational Research**, 201, 838-846, 2010.
- [25] B. Back, T. Laitinen ve K. Sere, "Neural network and genetic algorithm for bankruptcy prediction", **Expert Systems with Applications**, 11(4), 407-413, 1996.
- [26] R. Barniv, A. Anurag ve R. Leach, "Predicting the out come following bankruptcy filing: A three state classification using NN", **International Journal of Intelligent Systems in Accounting Finance and Management**, 6, 177-194, 1997.
- [27] B.A. Ahn, S.S. Cho ve C.Y. Kim, "The integrated methodology of rough set theory and artificial neural network for business failure prediction", **Expert Systems with Applications**, 18, 65-74, 2000.
- [28] H. Bian ve L. Mazlack, "Fuzzy-rough nearest neighbour classification approach", in: **22nd International Conference of the North American Fuzzy Information Processing Society, (NAFIPS 2003)** Proceedings Chicago, 500-505, 2003.
- [29] A. Cielen, L. Peeters ve K. Vanhoof, "Bankruptcy prediction using a data envelopment analysis", **European Journal of Operational Research**, 154, 526-532, 2004.
- [30] A.Y.N. Yip, "Predicting business failure with a case-based reasoning approach, lecture notes in computer science, in: M.G. Negoita, R.J. Howlett, L.C. Jain (Eds.), Knowledge-Based Intelligent Information and Engineering Systems", **8th International Conference, (KES 2004)**, Wellington, New Zealand, 20-25 Eylül 2004.
- [31] J.D. Andres, M. Landajove P. Lorca, "Forecasting business profitability by using classification techniques: A comparative analysis based on a Spanish case", **European Journal of Operational Research**, 167, 518-542, 2005.
- [32] Z. Hua, Y. Wang, X. Xu, B. Zhang ve L. Liang, "Predicting corporate financial distress based on integration of support vector machine and logistic regression", **Expert Systems with Applications**, 33(2), 434-440, 2007.
- [33] R.H. Lin, Y.T. Wang, C.H. Wu ve C.L. Chuang, "Developing a business failure prediction model via RST, GRA and CBR", **Expert Systems with Applications**, 36(2), 1593-1600, 2009.
- [34] H. Youn ve Z. Gu, "Predicting Korean lodging firm failures: An artificial neural network model along with a logistic regression model", **International Journal of Hospitality Management**, 29, 120-127, 2010.
- [35] A. Chaudhuri ve K. De, "Fuzzy support vector machine for bankruptcy prediction", **Applied Soft Computing**, 11(2), 2472-2486, 2011.
- [36] H. Li ve J. Sun, "On performance of case-based reasoning in Chinese business failure prediction from sensitivity, specificity, positive and negative values", **Applied Soft Computing**, 11(1), 460-467, 2011.
- [37] N. Benhayoun, I. Chairi, A. El Gonnouni ve A. Lyhyaoui, "Financial intelligence in prediction of firm's creditworthiness risk: Evidence from support vector machine approach", **Procedia Economics and Finance**, 5, 103-112, 2013.
- [38] N. Gordini, "A genetic algorithm approach for SMEs bankruptcy prediction: Empirical evidence from Italy", **Expert Systems with Applications**, 41, 6433-6445, 2014.
- [39] T. Bielíková, T. Bányiová ve A. Piterková, "Prediction techniques of agriculture enterprises failure", **Procedia Economics and Finance**, 12, 48-56, 2014.
- [40] W. Xu, Z. Xiao, X. Dang, D. Yang ve X. Yang, "Financial ratio selection for business failure prediction using soft set theory", **Knowledge-Based Systems**, 63, 59-67, 2014.

- [41]I. Stanimirova, M. Daszykowskive B. Walczak, "Dealing with values and outliers in principal component analysis", **Talanta**, 72(1), 172-178, 2007.
- [42]M. Çilli, **İnsan hareketlerinin modellenmesi ve benzeşiminde temel bileşenler analizi yönteminin kullanılması**, Doktora Tezi, Hacettepe Üniversitesi, Sağlık Bilimleri Enstitüsü, 2007.
- [43]P. Berkhin, **Survey of clustering data mining techniques**, Accrue SoftwareInc., San Jose, California, USA, 2002.
- [44]L. Sangün, L., **Temel bileşenler analizi, ayırma analizi, kümeleme analizleri ve ekolojik verilere uygulanması üzerine bir araştırma**, Doktora Tezi, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, 2007.
- [45]Hassoun, M.H., **Fundamentals of artificial neural networks**, MIT press, USA, 1995.
- [46]Graupe, D., **Principles of artificial neural networks**, World Scientific, 6.Baskı, 2007.
- [47]H. Erdal, "Makine Öğrenmesi Yöntemlerinin İnşaat Sektörüne Katkısı: Basınç Dayanımı Tahminlemesi". **Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi**, 21(3), 109-114, 2015.
- [48]Internet: Cornell Üniversitesi Resmi İnternet Sayfası,"Support Vector Machines",www.math.cornell.edu/~num3rs/kostyuk/num219.htm, 16.11. 2014.
- [49]X. Xu, C. Zhou ve Z. Wang, "Credit scoring algorithm based on link analysis ranking with support vector machine",**Expert Systems with Applications**, 36(2), 2625-2632, 2009.
- [50]S. Lucey, "Enforcing non-positive weights for stable support vector tracking", **Computer Vision and Pattern Recognition, CVPR 2008. IEEE Conference on**, 1-8, 23-28 Haziran 2008.
- [51]W.C. Hong, "Chaotic particle swarm optimization algorithm in a support vector regression electric load forecasting model",**Energy Conversion and Management**, 50(1), 105-117, 2009.
- [52]S. Piramuthu, "Financial credit-risk evaluation with neural neurofuzzy systems", **European Journal of Operation Research**, 112(2), 310-321, 1999.
- [53] A. Vellido, P.J.G. Lisboa ve J. Vaughan, "Neural networks in business: a survey of application (1992-1998)", **Expert System With Application**, 17, 51-70, 1999.
- [54]A.B. Graf ve S. Borer, "Normalization in support vector machines", **In Pattern Recognition**, Springer Berlin Heidelberg, 277-282, 2001.
- [55]H. Yumurtacı Aydoğmuş, A. Ekinci, H.İ. Erdal ve H. Erdal, "Optimizing the monthly crude oil price forecasting accuracy via bagging ensemble models", **Journal of Economics and International Finance**, 7(5), 127-136, 2015.
- [56]A. Chaudhuria ve K. Deb, "Fuzzy Support Vector Machine for bankruptcy prediction", **Applied Soft Computing**, 11, 2472-2486, 2011.
- [57]B. Ribeiro, C. Silva, N. Chen, A. Vieira veJ.C. Das Neves, "Enhanced default risk models with SVM+", **Expert Systems with Applications**, 39, 10140-10152, 2012.
- [58]K.S. Shin, T.S. Lee veH.J. Kim, "An application of support vector machines in bankruptcy prediction model", **Expert System With Application**, 28, 127-135, 2005.
- [59]Y.S. Ding, X.P. Song veY.M. Zen, "Forecasting financial condition of Chinese listed companies based on support vector machine", **Expert Systems with Applications**, 34, 3081-3089, 2008.
- [60]C.F. Tsai, "Feature selection in bankruptcy prediction", **Knowledge-Based Systems**, 22, 120-127, 2009.
- [61]N. Benhayouna, I. Chairia, A. El Gonnounia veA. Lyhyaouia, "Financial Intelligence in Prediction of Firm's Creditworthiness Risk: Evidence from Support Vector Machine Approach", **Procedia Economics and Finance**, 5, 103-112, 2013.
- [62]D. Delen, C. Kuzey veA. Uyar, "Measuring firm performance using financial ratios: A decision tree approach", **Expert Systems with Applications**, 40, 3970-3983, 2013.