



ISSN: 2146-1740  
<https://dergipark.org.tr/tr/pub/ayd>,

Araştırma Makalesi



## YAPAY ZEKÂ YÖNTEMLERİYLE SINIFLANDIRMA VE FİNANS SEKTÖRÜNDE KURUMSAL MÜŞTERİLERE DÖNÜK BİR UYGULAMA

CLASSIFICATION WITH ARTIFICIAL INTELLIGENCE METHODS AND AN  
APPLICATION FOR CORPORATE CUSTOMERS IN THE FINANCE SECTOR

Gökhan KORKMAZ<sup>1</sup>

Öz

***Makale Bilgi***

***Gönderilme:***  
***06/11/2020***

***Kabul:***  
***24/11/2020***

Bu çalışmada, sınıflandırma yöntemlerinden, yapay zekâ tabanlı, Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM) geleneksel yöntemlerden ise Lojistik Regresyon (LR) bir bankadan alınan kurumsal müşteri veri kümesine, iki farklı şekilde, uygulanmıştır. 893 tanesi “kusurlu”, 7896 tanesi “kusursuz” toplam 8789 adet kurumsal müşteri verisinin yer aldığı “kurumsal veri” kümesine ve ikincil olarak da 893 tanesi kusurlu, 893 tanesi kusursuz toplam 1786 adet müşteri verisinin yer aldığı “dengeli kurumsal veri” kümesine uygulanmıştır. Her iki veri kümesinde YSA en yüksek doğruluk oranını (sırasıyla %96 ve %93), DVM ise kurumsal veride yine en yüksek doğruluk oranını (%96), LR ise yapay zekâ tabanlı uygulamalara kıyasla daha düşük bir doğruluk oranı (%89) vermiştir. Kurumsal veriden, dengeli kurumsal veriye geçildiğinde, verideki yaklaşık %80’lik kayıptan, YSA ve LR %3 oranında etkilenirken DVM ise %5 oranında etkilenmiştir. DVM, modeller arasında, en küçük standart sapmaya sahip yöntem olmuştur. Çalışma, yapay zekâ tabanlı YSA ve DVM yöntemlerinin, LR gibi geleneksel yöntemlere kıyasla, daha iyi sonuçlar verdiğini, diğer bir deyişle daha iyi sınıflandırma yaptığını, göstermiştir.

**Anahtar Kelimeler:** Sınıflandırma, Yapay sinir ağları, Destek vektör makineleri, Kredi başvurusu değerlendirme.

**Abstract**

***Article Info***

***Received:***  
***06/11/2020***

In this study, among the classification methods, artificial intelligence-based, Artificial Neural Networks (ANN) and Support Vector Machines (SVM), and traditional methods, Logistic Regression (LR) were applied to the corporate customer data set from a bank in two different ways. 893 of them are flawed, 7896 of them are flawless, a total of 8789 corporate customer data is applied to the "corporate data" set, and secondary to the "balanced corporate data" set, which includes 1786 customer data, 893 of which are flawed and 893 of which are flawless. In both data

<sup>1</sup> Doktor, İstanbul Üniversitesi, ORCID ID: 0000-0002-1702-2965, gkhnkrkmz3873@gmail.com.

*Accepted:*  
*24/11/2020*

sets, ANN gave the highest accuracy rate (96% and 93%, respectively), DVM gave the highest accuracy rate (96%) in institutional data, and LR gave a lower accuracy rate (89%) compared to artificial intelligence-based applications. When transitioning from corporate data to balanced corporate data, while ANN and LR were affected by 3% from the loss of approximately 80% in data, SVM was affected by 5%. SVM was the method with the smallest standard deviation among the models. The study showed that AI-based ANN and SVM methods yield much better results than traditional methods such as LR, in other words, they classify better.

**Keywords:** Classification, Artificial neural networks, Support vector machines, Loan application evaluation.

## 1. Giriş

Bankaların başını çekmiş olduğu finans sektörü, ekonomilerin sürdürülebilirliği ve gelişmesi açısından stratejik ve çok kritik bir işlev olan, “fonlama” işlevini yerine getiren, hayati bir sektör niteliğindedir (Altan, 2001: 66). Finans sektörünün ana arterleri olan bankalar, ikincil olarak da diğer finans kurumları piyasayı kullandırmış oldukları krediler vasıtasıyla fonlamaktadırlar. Dolayısıyla fonlamanın sağlıklı yürütülebilmesi, fonlamanın en büyük kalemi olan kredi kullandırma faaliyetinin doğru yapılabilmesi ile yakından alakalıdır. Bu ise kullandırılan kredilerin bir kısmının ya da tamamının zamanında geri dönmeme ihtimalini belirten “kredi riski” olgusunun iyi yönetilebilmesi yani geri dönmeyen kredilerin minimize edilmesi ile mümkün olabilmektedir (Muzır, 2011: 10). Çünkü risk, piyasa koşullarında, olmazsa olmaz bir kazanç kapısıdır ve fırsatlarla tehditleri içinde barındıran, ölçülemeyen ama yönetilebilen bir iş sürecidir (Yılmaz, 2010: 4). Bankalar bu riski minimize edebilmek adına çok farklı yöntemleri şimdiye kadar kullanagelmektedirler. Güncel anlamda yapay zekâ yöntemleri de bu yöntemler arasındadır. Hatta bazı bankalar, belli bir ölçüğe kadar olan kredi başvurularını, insani süreci tamamen aradan çıkararak, kredi talebi değerlendirme işlemlerini, yapay zekâ vasıtasıyla robotize etmektedirler.

Bankaların kredi süreçlerini değerlendirmeleri konusunda iki temel yaklaşım söz konusudur. Bunlar “dışsal” ve “içsel” ölçüm yaklaşımlarıdır. Dışsal ölçüm yaklaşımları, uluslararası kredi derecelendirme kuruluşlarının, şirketler ve ülkeler için sağlamış oldukları kredi notunu baz alarak değerlendirme yaklaşımını gütmektedir. İçsel ölçüm yaklaşımları ise, bankaların sadece kredi notlarına göre değil, kendi içsel tecrübe ve birikimleri doğrultusunda, kendilerine özgü olan, değerlendirme yaklaşımlarını kastetmektedir. Bu yaklaşımın her ikisi de Uluslararası Takas Bankası (The Bank of International Settlement, BIS) tarafından kurulan ve İsviçre’nin Basel kentinde toplandığı için “Basel Komitesi” adıyla anılan komitenin, 2008

yılı küresel mortgage krizinden sonra, tarihinde ikinci kez, toplanıp almış oldukları kararlara atfen “Basel II Kararları” içinde tavsiye kararı olarak deklare edilmiştir. Bu kararların herhangi bir cebriliği yoktur, fakat uluslararası akredite ve finansal danışmanlık hizmeti sağlamaktadırlar (Altay, 2015: 429).

Bu çalışmada bir bankadan alınan kurumsal müşteri veri kümesine, Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM) ve karşılaştırma imkânı elde etme açısından da geleneksel istatistiki yöntemlerden Lojistik Regresyon (LR) yöntemleri uygulanmıştır. Kredi başvurusu yapan bu müşterilerden hangilerinin riskli kategorisine girmeyip kredi başvurusunun olumlu cevaplandırılması, hangilerinin ise riskli bulunup taleplerinin reddedilmesi gerektiği ayırt edilmeye çalışılmıştır. Anlaşılacağı gibi bu problem, müşterileri “riskli” ve “risksiz” şeklinde iki sınıfa ayırma, yani bir çeşit sınıflandırma problemidir.

Sınıflandırma en çok başvurulmuş makine öğrenmesi problemlerinden birisi olup, bugün pek çok problem ya baştan bir sınıflandırma problemi olarak tasarlanmakta ya da bir sınıflandırma problemine dönüştürülüp ondan sonra çözülmektedir (Öztemel, 2012: 36). Sınıflandırma, veri kümesinde yer alan gözlemlerin temelde iki ayrı sınıfa, genelde ise iki ya da daha fazla kategorik sınıfa, ayırma şeklinde tasarlanan araştırma problemleridir. Sınıflandırmada, gözlemlerin kaç sınıfa ayrılacağı ve bu sınıfların etiketlerinin ne olacağı araştırmacı tarafından önceden belirlenir. Örneğin diyabet ünitesinde yer alan hastaların kan değerlerine uygulanacak bir analizin sınıfları, “diyabet” ve “diyabet değil” şeklinde olabilir ve oluşturulacak olan modelden bu hastaları bu iki sınıftan birisine ataması istenir. Bu sınıflar ve sınıf etiketleri uygulama öncesinde belirlenir. Uygulama öncesinde sınıf sayısı ve etiketleri belirleyebilme lüksüne sahip olmak, bu gözlemlere ait sonuç çıktılarının tamamına (denetimli öğrenme) ya da bir kısmına (yarı denetimli öğrenme) sahip olmayı gerektirir. Aksi takdirde bir sınıflandırma modeli oluşturmak mümkün olmaz. Bu çalışmada kredi talebinde tüm müşterilere ait çıktı sınıfları belli olup denetimli (supervised) öğrenme gerçekleştirilmiştir.

Kredi başvurularını değerlendirme problemi, literatürdeki kadim problemlerden birisi olup, şimdiye dek geleneksel ve yapay zekâ anlamında birçok yöntemle bu tip problemler çözülmeye çalışılmıştır.

Huang ve diğerleri, DVM’ni bir kredi riski belirleme yöntemi olarak incelerken kıyaslama açısından geri yayılım sinir ağını (Çok Katmanlı Algılayıcı, ÇKA), ABD ve Tayvan pazarları için kullanmışlardır. Hem ÇKA için hem de DVM yöntemleri için yaklaşık % 80 tahmin doğruluğu elde ettikleri çalışmada DVM’in YSA’ya göre çok az bir ilerleme

gösterdiği bulgusuna ulaşmışlardır. Araştırmanın diğer bir konusunun, “yapay zekâ tabanlı modellerin yorumlanabilirliğini geliştirmek” olduğu ifade edilen çalışmada, YSA modellerinin yorumlamasında güncel araştırma sonuçlarını uygulayarak ve YSA modellerinden girdi finansal değişkenlerinin mukayeseli önemini alarak bunu gerçekleştirmeye çalışmışlar fakat bunu yapabilmek için daha derin ve daha kapsamlı pazar analizine ihtiyaç duyduklarını belirtmişlerdir (Huang vd., 2004: 544).

Baesens ve diğerleri, makalelerinde, bazı önemli veri setleri olan büyük Benelüks ve İngiltere finans kuruluşlarından gelen sekiz gerçek hayat kredi değerlendirme verisine, LR, LDA, K-en yakın komşu, YSA ve karar ağaçları gibi birçok yöntemi uygulamışlardır. O yıllarda bilinen bu yöntemlere ek olarak henüz yeni yeni kullanılmaya başlanan DVM ve en küçük kareler destek vektör makineleri (EKK-DVM, Least Squares Support Vector Machine, LS-SVM) gibi gelişmiş çekirdek tabanlı sınıflandırma algoritmasını da uygulamalarında kullanmışlardır. Çalışmanın sonuçları ise, sınıflandırma doğruluğu ve alıcının çalışma karakteristik eğrisinin altında kalan alan kullanılarak değerlendirilmiştir. Performans farklılıklarının yorumunu, uygun test istatistikleri kullanılarak istatistiksel olarak yorumlanan çalışmada, hem EKK-DVM hem de YSA sınıflandırıcılarının çok iyi bir performans gösterdiği, ancak LR ve LDA gibi basit sınıflandırıcıların da kredi puanlaması için çok iyi performans gösterdiği şeklinde yapmışlardır (Baesens vd., 2003: 627).

Bu bir sınıflandırma problemi olduğu için, sınıflandırma yapabilen, diskriminant analizi en eskisi olmak üzere (Lyn, 2000: 151), MARS (Multiadaptive Regression Splines), LR, YSA, DVM, EKKDVM, genetik algoritma, K-en yakın komşu vb. yöntemler başta olmak üzere, sayısız hibrit yöntem de kullanılmıştır. Bu yöntemlerin bir kısmı Tablo 1’de listelenmektedir. Bu çalışmanın literatüre, çok sayıda (8789 adet) gözleme sahip gerçek hayat verisinin üç farklı yöntemle, iki farklı kriter ışığında ve bu çalışmaya özgü bir YSA mimarisi kullanılarak ve veri kümesini, orijinal ve dengelenmiş şeklinde iki ayrı veri yapısı üzerinde uygulanması sayesinde katkı sağlaması beklenmektedir. Literatürde genel olarak yapay zeka tabanlı yöntemlerin geleneksel yöntemlerden daha iyi olduğunu söyleyen birçok çalışma bulunmaktadır (West, 2000).

## **2. Yöntem**

Sınıflandırma problemi için kullanılan birçok yöntem bulunmaktadır. Bunlar çeşitli özelliklerine göre Tablo 1’de listelenmektedir. Tabloda yer alan yöntemlerin dışında da çeşitli sınıflandırma yöntemleri bulunmaktadır, fakat en çok kullanılanları bunlardır.

Bu çalışmada yapay zekâ tabanlı sınıflandırma yöntemlerinden YSA ve DVM, istatistik tabanlı yöntemlerden ise lojistik regresyon yöntemi kullanılmıştır. Lojistik regresyon, diskriminant analizi gibi katı varsayımlar gerektirmeyen ve sonuçları itibariyle daha başarılı olan bir istatitiki yöntem olarak ön plana çıkmaktadır (Harrell & Lee, 1985: 333). Sonuçlar ise doğruluk oranları ve standart sapmaları bağlamında iki farklı karşılaştırma kriteri kullanılarak mukayese edilmiştir. Uygulamada kullanılan eğitim kümeleri veri kümesi içerisinde, %80 oranında ve tesadüfi olarak program tarafından seçildiği için örneklem seçiminden kaynaklanan standart hatayı düşürmek adına bu seçim işleminin on kez (cv=10) tekrarlanıp analize tabi tutulup sonuçlarının ortalamasının yanı sıra standart sapmaları da birer karşılaştırma kriteri olarak kullanılmıştır.


Tablo 1  
*Sınıflandırma Problemlerinde Kullanılan Yöntemler ve Özellikleri*

<b>Özelliği</b>	<b>Türü</b>	<b>Karakteristik Özellikleri</b>	<b>Sınıflandırıcı Örnekleri</b>
<i>Eğitim örneklerinin kullanılıp kullanılmamasına göre</i>	<i>Denetimli sınıflandırma yaklaşımı</i>	<i>Yeterli referans verisi mevcuttur ve eğitim örneği olarak kullanılır. Eğitim örneklerinden üretilen imzalar daha sonra sınıflandırıcıyı spektral verileri tematik bir harita olarak sınıflandırmak üzere eğitmek için kullanılır.</i>	<i>_Maksimum olabilirlik, _Minimum mesafe, _YSA, _Karar ağacı</i>
	<i>Denetimsiz sınıflandırma yaklaşımı</i>	<i>Kümeleme tabanlı algoritmalar. Sınıfların önceki tanımları kullanılmaz. Analist, sınıfları anlamlı sınıflara etiketlemekten ve birleştirmekten sorumludur.</i>	<i>_ISODATA, _K-ortalama kümeleme algoritması</i>
<i>Ortalama vektör ve kovaryans matrisi gibi parametrelerin kullanılıp kullanılmadığına göre</i>	<i>Metrik (parametrik)</i>	<i>Gauss dağılımı varsayılır. Parametreler (örn., Ortalama vektör ve kovaryans matrisi) genellikle eğitim örneklerinden üretilir. Peyzaj karmaşık olduğunda, parametrik sınıflandırıcılar genellikle "gürültülü" sonuçlar üretir. Bir diğer önemli dezavantaj, yan verileri, mekânsal ve bağlamsal özellikleri ve istatistiksel olmayan bilgileri bir sınıflandırma prosedürüne entegre etmenin zor olmasıdır.</i>	<i>_Maksimum olabilirlik (Maximum likelihood), _Doğrusal diskriminant analizi</i>
	<i>Metrik olmayan (non-parametrik)</i>	<i>Veriler hakkında herhangi bir varsayım gerekli değildir. Parametrik olmayan sınıflandırıcılar, sınıf ayrımını hesaplamak için istatistiksel parametreler kullanmaz.</i>	<i>_YSA, _Karar ağacı, _Delil akıl yürütme, _DVM, _Uzman sistem.</i>

Kaynak: Lu, & Weng, 2006: 830.

## 2.1. Yapay Sinir Ağları

YSA, insanın beyninde yer alan ve ilk kez 1890 yılında Alman bilim adamı Heinrich Wilhelm Gottfried von Waldeyer-Hartz tarafından “nöron” olarak isimlendirilen sinir hücrelerinden esinlenilerek geliştirilmiş, çok merkezli, paralel bir hesaplama daha doğrusu modelleme yöntemidir (Anderson & Mcneill, 1992: 17-18). Sinir hücresi temelli ilk somut modelleme tekniği 1958 yılında, Frank Rosenblatt tarafından “basit algılayıcı (perceptron)” olarak tanıtılmıştır (Rosenblatt, 1958: 387). Şekil 1’de perceptronun yapısı görülmektedir.



Şekil 1.  
Perceptronun Yapısı  
Kaynak: Hamzaçebi, 2011: 37


Perceptronda girdiler ağırlıklarla ( $w$ ) çarpılarak sonraki nörona iletilir. Burada ağırlıklandırılmış vektörler sapmasında eklenerek genel formu Denklem 1’de görülen bir toplama fonksiyonuyla toplanır.

$$n_i^{net} = \sum_{j=1}^{j_i} w_{ji} n_j - \theta_i \quad (1)$$

Toplam değeri bir aktivasyon fonksiyonunda geçirilerek, bu değer sıfır ila bir arasında bir değer kazanarak ilgili sınıfa atanır.

Bugün bu haliyle perceptronlar oldukça basit kalmaktadır. Fakat bugün bu yapı üzerine inşa edilmiş çok sayıda algoritma bulunmaktadır. “Öğrenebilen” bu model doğrusal yapısıyla, AND ve OR gibi doğrusal yapıdaki tüm problemlere çözüm üretebilmiş fakat XOR gibi, doğrusal olmayan problemlere çözüm üretmediği Papert ve Minsky tarafından 1969 yılında

basılmış kitaplarında ispatlayınca, zaten yapay zeka konusunda ölçsüz çok sayıda haberden dolayı ütöpik bir misyon yüklenen yapay sinir ağlarına ilgi azalmış ve fonlar da kesilmiştir. 1982 yılında Rumelhart perseptronları yan yana ve alt alta ekleyerek daha kompleks ve kullanışlı bir sinir ağı geliştirmiştir. Çok Katmanlı Ağlar (ÇKA) denilen bu sinir ağının XOR problemini de çözebildiğinin 1985 yılında ispatının ardından sinir ağlarına olan ilgi yeniden canlanmıştır (Öztemel, 2012: 37). Şekil 2’de çok katmanlı bir sinir ağı görülmektedir.



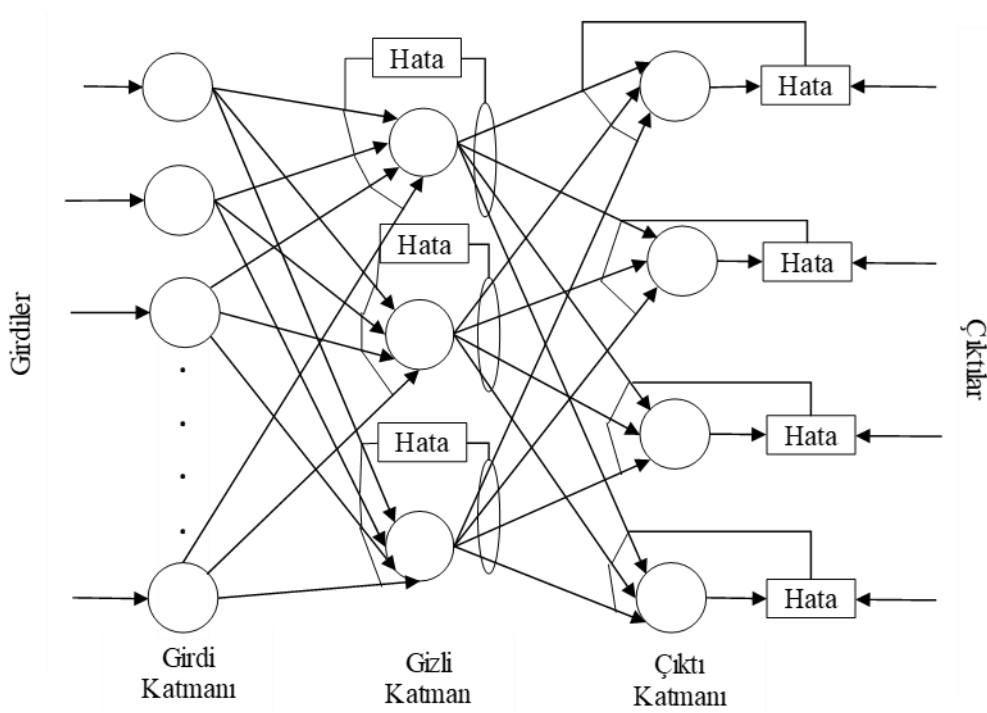
Şekil 2.  
Çok Katmanlı Algılayıcılar (ÇKA)  
Kaynak: Cura, 2008: 32

Giriş kısmındaki, gözlemleri temsil eden katman “girdi katmanı”, daha sonraki ara katmanlar “gizli katman” en son çıktı sınıflarının yer aldığı katman ise “çıkı katmanı” olarak isimlendirilmektedir. Şekil 2’de yer alan ÇKA’da iki adet gizli katman ve bu gizli katmanların her birincisinde beş adet ikincisinde ise altı adet nöron bulunmaktadır. Tüm daireler nöron olarak ya da işlemci prosesi olarak isimlendirilmektedir. Aradaki oklar ise ağırlıkları temsil etmektedir. Okların sağa doğru olması ise ağı bir “ileri beslemeli ağı” olduğunu göstermektedir.

Çok katmanlı algılayıcılarda girdi nöronlarında herhangi bir işlem yapılmaz. Sadece ilgili ağırlıklarla çarpılarak birinci gizli katmanın genellikle tüm nöronlarına iletilir. Bu şekilde değerler tüm ağıdan geçirilerek sonuç çıktıları üretilir. Ağların çok katmanlı olması,

onlara nonlinear bir yapı kazandırır. Böylelikle XOR gibi doğrusal olmayan problemler de ÇKA kullanılarak çözülebilir.

Çok katmanlı ağların, delta öğrenme kuralı vasıtasıyla geriye yayımlı olarak iteratif hale getirilmesi ise sinir ağlarının performansını çok artırmış ve sayısız çalışmada kullanılmasını sağlamıştır. Aşağıdaki şekilde çok katmanlı ve geriye yayımlı bir sinir ağı modeli görülmektedir.



Şekil 3.  
Geriye Yayımlı Bir Ağ Mimarisi  
Kaynak: Elmas, 2016: 115

Geriye yayımlı ağda farklı olarak, eğer üretilen çıktı sonuç çıktısıyla uyuşmuyorsa, belli bir hata payı (öğrenme oranı) eklenerek tüm hesaplar aynı şekilde geriye doğru yürütülür. Buna geriye yayılma işlemi denilir. Geriye yayımlı YSA'larda aktivasyon fonksiyonu, türevi alınabilir bir fonksiyon olmalıdır. Çünkü tüm bu değişimler diferansiyel olarak yani türev alınarak yapılmaktadır. Geriye yayımlı algoritmada amaç hata payı ölçüsünde ilk başta rasgele atanan ağılıkların güncellenerek oluşturulan modelin (fonksiyonun parametrelerinin) optimize edilmesidir. Bu süreç defalarca bazen on binlerce iterasyonla tekrarlanır ve en uygun model, model hatası baz alınarak bu hataların minimum noktası en küçük kareler yöntemiyle elde edilerek iteratif döngü durdurulur ve oluşturulan model kullanıma sunulur. Modelin performansına bakmak içinse ilk başta elde edilen modelin bir kısmı



test verisi olarak ayrılır. Geriye kalan “eğitim verisi” ile model eğitilir ve test verisindeki sonuç performansı, modelin doğruluk oranı olarak kabul edilir.

ÇKA’da doğrusala yakın problemlerde tek gizli katman, çok karmaşık veri kümelerinde ise iki gizli katman kullanılmaktadır. Daha fazlası ise pek kullanılmamaktadır. Gereğinden fazla gizli katman, nöron ya da iterasyon sayısı ağırlık eğitim verisini adeta ezberlemesine sebep olmakta bu da modeli eğitim verisine bağımlı hale getirmektedir. Yani model bir anlamda, veri kümesi içerisinde yer alan fonksiyonel örüntüleri öğrendikten sonra verinin içinde yer alan gürültüyü de ezberlemektedir (Emir, 2013). Bu ise modelin, aynı olasılık dağılımına sahip, test verisinde iyi sonuç vermesine fakat daha sonraki veri kümelerinde oldukça düşük performans göstermesine neden olmaktadır. Bu durum aşırı uyum (overfitting) olarak, tersi durumda yani eğitim verisine yeterli uyumu sağlayamaz ise bu kez eksik uyum (underfitting) olarak betimlenmektedir. Bu ise düşük eğitim hatasına fakat yüksek genelleme hatasına karşılık gelmektedir. Oysaki iyi bir model, eğitim verisine odaklanma ile diğer verilere uyarlanabilme (genelleme) arasındaki dengeyi iyi kurabilmelidir. Yani eğitim hatası ile genelleme hatasını birlikte minimize edebilmelidir (Shen, 2005).

YSA, tek merkezli değil adeta nöron adedince merkezli bir model (bir anlamda hesap makinesi) olduğu için, işlemler paralel olarak yürütüldükleri için sinir ağı veride yer alan gürültü, uç değerler gibi olumsuz unsurlardan etkilenmez. Yüksek genelleme kabiliyetine sahiptir. Yine işlemler birçok merkezden yürütüldüğü için verideki dejenerasyondan en geç etkilenen yöntemdir. İyi oluşturulmuş bir YSA mimarisinin çözemeyeceği problem çok azdır (Öztemel, 2012: 207).

Çok katmalı bir YSA mimarisi oluştururken uygulayıcının bazı parametreleri optimal olarak ayarlaması gerekmektedir. Bunlar gizli katman sayısı, her bir gizli katmanda bulunacak nöron sayısı, nöronlardaki toplama fonksiyonu, aktivasyon fonksiyonu, momentum katsayısı ve iterasyon sayısıdır. Bu parametrelerin optimum değerlerini bulmamızı sağlayacak bir yaklaşım günümüzde mevcut değildir. Bundan dolayı uygulayıcı tüm bu parametrelerin optimal değerini deneme-yanılma yoluyla elde etmesi gerekmektedir. Bu ise ciddi bir zaman kaybını beraberinde getirmektedir. Ayrıca en küçük karelerle karar verilen minimum hata noktası yerel olabilir, global olmayabilir. Bulunan minimum noktanın yerel mi yoksa global mi olduğu da anlaşılabilir. Ayrıca gizli katmanlardan geçen YSA’nın parametreleri yani katsayıları bir regresyon formülündeki gibi açık değildir. O yüzden hangi açıklayıcı değişkenin bağımlı değişken üzerinde daha etkili olduğu bilinmemektedir. Model bunu kendi

içerisinde Hebb tabanlı öğrenme tekniklerini, yani paralel çalışan nöronların benzer sonuçlar (matematiksel olarak aynı işaretli) üretenler arasındaki katsayıyı artırma yoluyla gerçekleştirmektedir. Bu yüzden modelin içeriği bilinmemekte bu ise YSA'nın "kara kutular" olarak bilinmesi sonucunu doğurmakta bu da iş süreçlerinde şeffaflıktan uzaklaşma olarak yorumlanmaktadır (Yakut, 2012: 122; Nabiye, 2016: 599).

## **2.2. Destek Vektör Makineleri**

DVM'nin YSA'ndan farkı, aslında diğer tüm sınıflandırma yaklaşımlarından farkı, ampirik risk minimizasyonu ilkesi yerine Yapısal Risk Minimizasyonu (YRM) ilkesine dayanan bir hata minimizasyonu tekniği geliştirmesidir (Çomak, 2008). Ampirik risk minimizasyonu nedir? Modeller doğru tahminleme yapabilmek için, hatalarını minimize etme yoluna giderler. Hata ya da risk olarak adlandırılan ve modelin gerçek çıktı değerinden farklı bir çıktı üretmesi olarak tanımlanan ampirik risk ilkesi aslında gerçek riskin aynısı değildir. Gerçek risk, kullanılan diğer ismiyle beklenen risk (Vapnik, 1999: 989),


$$R(\alpha) = \int L(y, f(x, \alpha)) dP(x, y) \quad (2)$$

şeklinindedir. Fakat burada veri kümesinin olasılık dağılımı, yani  $dP(x, y)$ , bilinmediği için bu formülle risk minimizasyonu gerçekleştirilememektedir. Beklenen risk minimize edilemediği için, onun yerine ampirik risk minimizasyonuna gidilir:

$$R_{emp}(\alpha) = \frac{1}{n} \sum_{i=1}^n ((y_i - f(x_i, \alpha))^2) \quad (3)$$

İstatistikte merkezi limit teoremi gereği, örnekleme ne kadar büyür ve ana kütleyle yaklaşır, standart hata o kadar azalır. Yani örneklemin anakütleyi temsil kabiliyeti artar. Hatta örneklem büyür ve anakütleye eşit olursa bu durumda standart hata sıfır (0) olacaktır. Ne var ki ana kütle sonsuza da eşit olabilir. Böyle bir ilişki ampirik risk ile beklenen risk arasında da vardır ve bu ikisi arasındaki fark gözlem sayısı sonsuza eşit olduğunda tam anlamıyla kapanır. Bu durum denklem 4'te ve Şekil 4'te gösterilmektedir.


$$[R(\alpha) - R_{emp}(\alpha)] = 0 \quad (4)$$



Şekil 4.  
*Ampirik Risk Ve Beklenen Risk İlişkisi*  
Kaynak: Cherkassky & Mulier, 2007: 103.

Regresyondaki en küçük hata kareleri toplamı ve yoğunluk tahminindeki maksimum olabilirlik yöntemleri ARM'nun probleme dönük olarak özelleştirilmiş halleridir. Yani ARM çok genel bir ilkedir (Vapnik, 1999: 990). Fakat Şekil 4'ten de anlaşılacağı gibi, ampirik risk gerçek risk anlamına gelmemekte ve bu ikisinin birbirine yaklaşabilmesi için, sonsuz değilse bile, çok sayıda gözleme ihtiyaç duyulmaktadır. Üstelik bu yöntem eğitim hatasını minimize ederken genelleme hatasını da kontrol etmeye dönük bir formülasyon sağlamamaktadır. Bu durum ise eğitim verisine aşırı odaklanmayı yani aşırı öğrenmeyi, bir bakıma veriyi ezberlemeyi, içerik olarak ise verinin içinde yer alan örüntülerin ardından veride yer alan gürültüye de ezberlemeye neden olmaktadır.

Vapnik ve Chervonenkis, ARM ilkesinin tutarlılık sınırlarını, matematiksel olarak, belirlemeye çalışırken bir VC boyutu geliştirmişlerdir.  $Q(z, \alpha), \alpha \in \Lambda$  şeklinde gösterilen gösterge fonksiyonlarının bir kümesinin VC boyutu ( $h$  ile gösterilir), bu işlevler tarafından parçalanmış bu kümenin tüm  $2^h$  muhtemel yolla kullanılabilen fonksiyonlarının, ayrılabilen  $z_1, z_2, \dots, z_h$  vektörlerin maksimum  $h$  sayısıdır (Vapnik & Izmailov, 2017: 4). Daha basit bir tanımla VC boyutunu şu şekilde de tanımlayabiliriz: Eğer  $n$  adet örneklem temsilci fonksiyonların tamamı tarafından olası  $2^n$  durumun tamamında ayrılabilirse, o zaman bu örneklem kümesinin bu fonksiyon kümesi ile ayrıştırılabildiği söylenir ve VC boyutu  $h = n$  olur. Ampirik risk ile VC boyutu birlikte minimize edilirse bu durumda her iki hata da minimize edilebilmektedir. Bu durum Şekil 5'te gösterilmektedir (Çomak, 2008).




Şekil 5.

*VC Boyutu Deneysel Risk İle Birlikte Minimize Edilirse Beklenen Riskin Minimize Edilebileceğinin Grafikselleştirilmesi*

Kaynak: Theodoridis & Koutroumbas, 2009: 119.

Şekil 5'e bakıldığında, YSA gibi sadece ampirik riski (deneysel risk) minimize etmeye çalışan yöntemler  $h_m$  noktasındaki parametreleri optimum olarak alırken, DVM yöntemi ise  $h^*$  noktasındaki parametreleri, optimum parametreler olarak, kullanılmaktadır. Bu durumda DVM, YSA gibi yerel minimum noktalara takılmadan doğrudan evrensel minimuma gitmektedir. Ayrıca, ARM ilkesini kullanan yöntemlerde olduğu gibi, her iki risk olgusu arasındaki farkı kapatmak için, çok sayıda gözleme ihtiyaç duymaz. Az sayıda gözlemlerle de uygun sonuçları verebilir. Tüm bu anlatılanlar, yani VC boyutunu kullanan Yeni Risk Minimasyonu anlayışı (YRM), İstatistiksel Öğrenme Teorisi (Statistical Learning Theory, SLT) olarak bilinmektedir. Şimdi Şekil 6'ya bakalım.



Şekil 6 (a/b).

*Hiperdüzlemlerle Ayrılmış İki Boyutlu Girdi Uzayı*

Kaynak: Kecman, 2005: 13

Hem Şekil 6a’da, hem Şekil 6b’de farklı iki sınıfa ayrılmış gözlemler bulunmaktadır. Sınıflandırma aslında bu iki gözlem sınırı arasına, iki sınıfın tüm gözlemlerini birbirinden ayıracak şekilde, bir hat, diğer adıyla bir hiperdüzlem (hyperplane) çizmektir. YSA’da bu şekilde çalışır. Zaten YSA’da nöronlar arasındaki ağırlıkları değiştirmek, bu hiperdüzlemin eğimiyle oynamaktır (Öztemel, 2012). DVM, YSA’ndan farklı olarak sadece bir hat çizmiyor ve Şekil 6’daki gibi, iki marjinle bu hattı bir blokaja dönüştürüyor. Bu blokajı da Şekil 6a’daki gibi rasgele ki bu hiperdüzlem de iki sınıfı birbirinden gayet rahat ayırabilmektedir, Şekil 6b’deki gibi bu iki gözlem sınıfı arasına çizilebilecek milyonlarca hiperdüzlemden, sınıflar arasındaki mesafeyi maksimize edecek hiperdüzlemi belirleyerek bu blokajı en kalın formuna getirmektedir. Böylelikle daha sonraki gözlemleri ayırmada b’deki sınıflandırma performansı a’dakinden daha iyi olacaktır.

### **3. Uygulama**

Uygulamada verilerin düzenlenmesi aşamasında Excel’in 2016 sürümü, analizlerin yapılması aşamasında ise Python 3.8.1 sürümü ve arayüz olarak da PyCharm kullanılmıştır. Kullanılan veri kümesi bir bankadan alınmış, kurumsal müşterilere ait olan, gerçek hayat verisidir. Veri kümesinde 16 adet açıklayıcı değişken (veri bankadan makyajlanmış olarak alındığı için bu açıklayıcı değişkenlerin ne olduğu bilinmemektedir) ve müşterilere ait sonuç çıktıları bulunmaktadır. Sonuç çıktıları, “Kusurlu” olan müşteriler için bir (1), “kusursuz” olan müşteriler için ise sıfır (0) şeklinde etiketlenmiş olup, iki sınıfa ayrılmıştır.

Analiz aşamasında, edinilen verinin tamamının yer aldığı bir veri kümesi (Kurumsal Veri Kümesi) bir de kusurlu ve kusursuz müşterilerin sayılarının eşitlendiği dengeli bir veri kümesi (Dengeli Kurumsal Veri Kümesi) oluşturulmuştur. Oluşturulan müşteri sınıflarının özellikleri, sınıf etiketleri ve her sınıfa düşen müşteri sayısı Tablo 3 ve Tablo 4’te görülmektedir.

Tablo 2  
*Kurumsal veri Sonuç Sınıfları ve Sınıf Etiketleri*

<i>Sınıfı</i>	<i>Sınıf Adı</i>	<i>Müşteri Sayısı</i>	<i>Verideki Miktarı (%)</i>
<i>0</i>	<i>Kusursuz Müşteri</i>	<i>7896</i>	<i>89,84</i>
<i>1</i>	<i>Kusurlu Müşteri</i>	<i>893</i>	<i>10,16</i>
<i>Toplam Kurumsal Müşteri Sayısı</i>		<i>8789</i>	<i>100,00</i>

Tablo 3  
*Dengeli Kurumsal Veri Sınıf Etiketleri*

<i>Sınıfı</i>	<i>Sınıf Adı</i>	<i>Müşteri Sayısı</i>	<i>Verideki Miktarı (%)</i>
0	<i>Kusursuz Müşteri</i>	893	50,00
1	<i>Kusurlu Müşteri</i>	893	50,00
<b><i>Toplam Kurumsal Müşteri</i></b>		<b>1786</b>	<b>100,00</b>

Normalizasyon aşamasında ise, “Min-Max Normalleştirilmesi” (Bkz. Denklem 5) yapılmıştır.

$$x' = \frac{x - x_{min}}{x_{maks} - x_{min}} \quad (5)$$

#### 4. Sonuçlar

YSA ve DVM yapay zekâ tabanlı uygulama sonuçları geleneksel yöntemlerden lojistik regresyon sonuçlarıyla kıyaslanmıştır. Bankadan edinilen tüm bilgiler modele birer açıklayıcı değişken olarak ilave edilmiştir. Kurumsal veri kümesi üzerinde yapılan birçok deneme neticesinde YSA mimarisi olarak: on (10) adet nörondan oluşan tek gizli katmanlı, iterasyon sayısı on bin (10000) ve standart hatayı azaltmak için her eğitim veri kümesi (%80) seçme ve analize tabi tutma işleminin on (10) kez yinelendiği bir ağ yapısının en iyi sonuçları verdiği tespit edilmiş ve aynı mimari yapı dengeli kurumsal veriye de aynen uygulanmıştır.

Tablo 4  
*Kurumsal Veri Kümesi Uygulama Sonuçları*

<i>Uygulamada Kullanılan Veri Kümeleri</i>	<i>Uygulama Sonuçları</i>			
	<i>Doğruluk Oranları Ve Standart Sapmaları</i>	<i>Uygulamada Kullanılan Yöntemler</i>		
		<i>YSA</i>	<i>DVM</i>	<i>LR</i>
<i>Kurumsal Veri Kümesi İle Yapılan Uygulama*</i>	<i>Doğruluk Oranı (%)</i>	<b>96</b>	<b>96</b>	<b>89</b>
	<i>Standart Sapma (%)</i>	<b>1</b>	<b>1</b>	<b>4</b>
<i>Dengeli Kurumsal Veri Kümesi İle Yapılan Uygulama**</i>	<i>Doğruluk Oranı (%)</i>	<b>93</b>	<b>91</b>	<b>86</b>
	<i>Standart Sapma (%)</i>	<b>4</b>	<b>2</b>	<b>3</b>

\*: 7896 kusursuz, 893 kusurlu olmak üzere, toplam 8789 kurumsal müşteri veri kümesiyle yapılan uygulama.

\*\* : 893 kusursuz, 893 kusurlu olmak üzere, toplam 1786 dengelenmiş kurumsal müşteri veri kümesiyle yapılan uygulama.

Tablo 4'e bakıldığında, genel olarak modellerin başarı performansının oldukça yüksek olduğu görülmektedir. Bunun üç önemli sebebinden ilki, açıklayıcı değişkenlerin bağımlı değişkeni açıklama gücü, ikincisi gözlem sayılarının oldukça yüksek oluşu ve üçüncü ise çıktı sınıflarının "kusurlu" ve "kusursuz" şeklinde iki sınıf halinde alfanümerik hale getirilmiş olmasıdır. Eğer çıktı sınıfları "kusursuz (0)", "az kusurlu (1)", "orta kusurlu (2)" ve "çok kusurlu (3)" şeklinde kategorilere ayrılmış olsa, her kategoriye de az ya da çok dengesiz miktarlarda müşteri sayısı düşeceği için modeller bu şekildeki veri kümeleri için oldukça zorlanmakta ve başarı oranları da doğal olarak düşmektedir.

Kurumsal veriden dengeli kurumsal veriye geçildiğinde, modellerin başarı performansının %3 ila %5 aralığında azaldığı görülmektedir. Bu düşüşün sebebi veride meydana gelen yaklaşık %80'lik azalış olduğu bu da veride yer alan örüntülerin deşifreyonunu zorlaştırmış olduğu aşikârdır. Bu oranda bir azalış karşılığında, doğruluk oranlarında meydana gelen kaybın bu kadar az olması, modelin tecrübesini oluşturan veri kümesinin data kalitesinin oldukça yüksek olması şeklinde yorumlamak mümkündür.

YSA her iki veri kümesinde de en yüksek doğruluk oranlarını veren yöntem olmuştur. YSA mimarisi oluşturulurken, bu çalışmada da olduğu gibi, modelin sahip olduğu mimari yapı, doğruluk oranları üzerinde son derece etkindir. Bu çalışmada YSA için kurulan mimari (on nöronlu tek gizli katman ve 10000 iterasyon, aktivasyon fonksiyonu olarak sigmoid fonksiyon ve on tekrar sayısı) en yüksek doğruluk oranlarını veren model olmuştur. Fakat mimarisinin parametrelerinin optimize edilmesi de günlerce sürmektedir.

DVM'nin de kurumsal dengeli veride %96 gibi en yüksek doğruluk oranını ve bunun yanı sıra en küçük standart sapmayı vermiş, verideki azalıştan ise en çok etkilenen model olup %5'lik bir kayıp yaşamıştır. Ama yine en küçük standart sapmaya sahiptir. Standart sapmanın küçük olması modele güveni artırmaktadır. Çünkü yapılan her analizde hemen hemen aynı doğruluk oranı yinelemektedir. Verideki %80'lik azalıştan en çok DVM etkilenmiştir. DVM için, az sayıda gözlemle (gerçi 1786 gözlem sayısı olarak az değildir) en iyi sonucu veren yöntem tespiti, bu çalışma için, geçerli olmamıştır. Ama yine de çok yüksek doğruluk oranı vermiştir. Ayrıca YSA'na kıyasla, DVM yönteminde, çekirdek fonksiyonunu belirledikten sonra (ki en çok kullanılan çekirdek fonksiyonu radyal tabanlı fonksiyondur) tek bir hamlede sonuç alınabilmektedir. Bu açıdan YSA'na kıyasla uygulaması oldukça kolaydır.

Geleneksel yöntemlerin, bugün, bu tarz problemlerde kullanılmalarının önemli bir sebebi yapay zekâ yöntemlerinin başarı performansını değerlendirebilmektir. Bu çalışmada yapay zekâ yöntemleri, geleneksel bir yöntem olan lojistik regresyona göre oldukça yüksek performans göstermiştir. Fakat lojistik regresyon gibi yöntemlerin basit arka planı sayesinde çok hızlı sonuç alınabildiği, YSA gibi yöntemlerin ise mimarisini olgunlaştırmanın ve bilgisayarda 50000-100000 gibi iterasyon sayılarına ulaşmanın zorluğu da göz önünde bulundurulmalıdır.

## **5. Yorumlar**

Günümüz iş süreçlerinde yapay zekânın kullanımı, tıpkı bir zamanlar bilgisayarların iş süreçlerinde kullanılmaya başlanması gibi, kaçınılmaz ve de geriye de dönülemez bir hal almaktadır. Çünkü yapay zekâ sayesinde, günlerce sürebilen ve birçok personelin yoğun emeğini gerektiren kredi başvurusu değerlendirme süreçleri, yapay zekâ ile saniyeler sürmektedir. Ayrıca insani süreçlerden, tabii zamanla bu sistemler olgunlaştıkça, daha doğru yürütme kapasitesini barındırmaktadır. İlgili personel bu sayede iş geliştirme vb. daha nitelikli işlerde istihdam edilebilmekte ve böylelikle iş süreçleri tüm angaryalardan güvenilir bir şekilde arındırmaktadır.

Bu çalışmada görülmektedir ki, bankaların kredi başvurularını içsel ölçüm yaklaşımıyla değerlendirme süreçlerinde, YSA ve DVM gibi yöntemler, zamanla veri birikimi sağlandıkça ve YSA ağları kuruma özgü bir şekilde olgunlaştırıldıkça son derece güvenilir sonuçlar üretmektedirler. Bu çalışma sonucunda, bankaların kendi sinir ağlarını kurmada ve yapay zekâyı iş süreçlerine hızlı bir şekilde dâhil etmekte gecikmemeleri gerektiği kanaati oluşmaktadır.

Türkiye’de, dokuz bankanın veri havuzlarını birleştirerek ve birçok algoritmalar kullanarak oluşturdukları Findeks kredi notu uygulaması, oldukça başarılı bir şekilde uygulanmaktadır. Fakat Findeks de bir dışsal ölçüm yaklaşımıdır ve bu kredi notunun homojenize ettiği bir piyasada en düşük faizli kredileri sunmadıkça rekabet etmek, sunarak da kar elde etmek çok mümkün görünmemektedir. Çünkü kâr, her zaman risktedir. Ama bu riski, herkesten bağımsız, kendine özgü model oluşturarak yönetebilme yetisi firmaların kârını ve rekabet edebilirliğini artıracaktır.



Bundan sonraki çalışmalarda, hangi veri boyutu aralığında DVM'nin YSA'na kıyasla daha avantajlı bir yöntem hale geldiğini tespit etmeye dönük çalışmaların literatüre pozitif anlamda katkı sağlaması beklenmektedir.

## KAYNAKÇA

- Altan, M. (2001). *Fonksiyonlar ve işlemler açısından bankacılık*. Beta Basım Yayıncılık.
- Altay, E. (2015). *Bankacılıkta risk, piyasa riski kredi riski ve operasyonel riskin ölçümü ve yönetimi*. Derin Yayınları.
- Anderson D. & Mcneill G. (1992). Artificial neural networks technology, *A DACS State-of-the-Art Report*, Contract Number F30602-89-C-0082.
- Baesens, B., Setiono, R., Mues, C. & Vanthienen, J. (2003). Using neural network rule extraction and decision tables for credit-risk evaluation, *Management Science*, 49 (3), 312-329.
- Cherkassky, V. & Mulier, F. (2007). *Lerning from data: consepts, theory and methods*. 2. Baskı, John Wiley & Sons, Inc.
- Cura, T. (2008). *Modern sezgisel teknikler ve uygulamaları*. Papatya Yayıncılık.
- Çomak, E. (2008). *Destek vektör makinelerinin etkin eğitimi için yeni yaklaşımlar*. (Yayımlanmamış Doktora Tezi), Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Elmas, Ç. (2016). *Yapay sinir ağları*. (3. Baskı). Seçkin Yayıncılık.
- Emir, Ş. (2013). *Yapay sinir ağları ve destek vektör makineleri yöntemlerinin sınıflandırma performanslarının karşılaştırılması: Borsa endeksi yönünün tahmini üzerine bir uygulama*. (Yayımlanmamış Doktora Tezi), İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Hamzaçebi, C. (2011). *Yapay sinir ağları tahmin amaçlı kullanımı, MATLAB ve NEUROSOLUTION uygulamalı*. Ekin Yayınevi.
- Harrell, F. E. & Lee Jr. K. L., (1985). A comparison of the discrimination of discriminant analysis and logistic regresyon under multivariate normality, *S.K. Se (Ed.), Biostatistics: Statistics in biomedical, public health, and environmental sciences*, North-Holland.
- Huang, Z., Chen, H., Hsu, C. J., Chen, W. H. & Wu, S. (2004). Credit rating analysis with support vector machines and neural networks: A market comparative study, *Decision Support Systems*, 37, 543– 558.
- Kecman, V. (2005). Support vector machines – An introduction, *StudFuzz*, 177, 1-47.
- Lu, D. & Weng, Q. (2006). A survey of image classification methods and techniques for improving classification performance, *International Journal of Remote Sensing*, 28 (5), 823-870.
- Lyn, T.C. (2000). A survey of credit and behavioural scoring: Forecasting financial risk of lending to consumers, *International Journal of Forecasting*, 16 (2), 149-172.
- Muzır, E. (2011). *Basel II düzenlemeleri doğrultusunda kredi riski analizi ve ölçümü: Geleneksel ekonometrik modellerin yapay sinir ağı ve mars modelleriyle karşılaştırılmasına yönelik ampirik bir çalışma*. (Yayımlanmamış Doktora Tezi), İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Nabiyev, V. (2016). *Yapay zekâ*. (5. Baskı). Seçkin Yayınevi.
- Öztemel, E. (2012). *Yapay sinir ağları*. Papatya Yayıncılık.
- Rosenblatt, F. (1958). The perceptron: A porobabilistic model for information storage and organization in the brain, *Psychonanalytic Review*, 65 (6), 386-408.
- Shen, J. (2005). *Fusing support vector machines and soft computing for pattern recognition and regression*. (Yayımlanmamış Doktora Tezi), Kansas State University, Kansas.
- Theodoridis, S. & Koutroumbas, K. (2009). *Pattern recognition*. (4. Baskı). Elsevier Inc.

Vapnik, V. (1999). An overview of statistical learning theory, *IEEE Transactions on Neural Networks*, 10 (5), 988-999.

Vapnik, V. & Izmailov, R. (2017). Knowledge transfer in SVM and neural networks, *Ann Math Artif Intell*, 81, 3-19.

West, D. (2000). Neural network credit scoring models, *Computers & Operations Research*, 27, 2000, 1131-1152.

Yakut E. (2012). *Veri madenciliği tekniklerinden C5.0 algoritması ve destek vektör makineleri ile yapay sinir ağlarının sınıflandırma başarılarının karşılaştırılması: İmalat sektöründe bir uygulama*. (Yayımlanmamış Doktora Tezi), Atatürk Üniversitesi Sosyal Bilimler Enstitüsü, Erzurum.

Yılmaz, E. A. (2010). *Basel II kapsamında kredi riski ve temerrüt olasılığı hesaplama yolu ile tespiti*. (Yayımlanmamış Doktora Tezi), Gazi Üniversitesi Sosyal Bilimler Enstitüsü, Ankara.