


Yapay Sinir Ağları İle İşletmelerin Mali Başarısızlıklarının Öngörülmesine İlişkin Bir
Çalışma

Ercan Akdeniz

YÜKSEK LİSANS TEZİ

Endüstri Mühendisliği Anabilim Dalı

Mayıs 2018



Using Neural Networks to Predict Corporate Financial Failure

Ercan Akdeniz

MASTER OF SCIENCE THESIS

Department of Industrial Engineering

May 2018

Yapay Sinir Ağları İle İşletmelerin Mali Başarısızlıklarının Öngörülmesine İlişkin Bir
Çalışma

Ercan Akdeniz

Eskişehir Osmangazi Üniversitesi

Fen Bilimleri Enstitüsü

Lisansüstü Yönetmeliği Uyarınca

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Bilim Dalı

YÜKSEK LİSANS TEZİ

Olarak Hazırlanmıştır.

Danışman: Prof. Dr. Muzaffer KAPANOĞLU

Mayıs 2018

ONAY

Endüstri Mühendisliği Anabilim Dalı Yüksek Lisans öğrencisi Ercan Akdeniz'in Yüksek Lisans tezi olarak hazırladığı “Yapay Sinir Ağları İle İşletmelerin Mali Başarısızlıklarının Öngörülmesine İlişkin Bir Çalışma” başlıklı bu çalışma, jürimizce lisansüstü yönetmeliğinin ilgili maddeleri uyarınca değerlendirilerek oybirliği ile kabul edilmiştir.

Danışman : Prof. Dr. Muzaffer KAPANOĞLU

Yüksek Lisans Tez Savunma Jürisi:

Üye: Prof. Dr. Muzaffer KAPANOĞLU

Üye: Prof. Dr. Hasan DURUCASU

Üye: Dr. Öğr. Üyesi Yeliz BURUK ŞAHİN

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun tarih ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Hürriyet Erşahan
Enstitü Müdürü

ETİK BEYAN

Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre, Prof. Dr. Muzaffer Kapanoğlu danışmanlığında hazırlamış olduğum “Yapay Sinir Ağları İle İşletmelerin Mali Başarısızlıklarının Öngörülmesine İlişkin Bir Çalışma” başlıklı tezimin özgün bir çalışma olduğunu; tez çalışmamın tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; tezimde verdiğim bilgileri, verileri akademik ve bilimsel etik ilke ve kurallara uygun olarak elde ettiğimi; tez çalışmamda yararlandığım eserlerin tümüne atıf yaptığımı ve kaynak gösterdiğimi ve bilgi, belge ve sonuçları bilimsel etik ilke ve kurallara göre sunduğumu beyan ederim. 28.05.2018

Ercan Akdeniz

ÖZET

Finansal başarısızlık tahmini üzerine literatürde çok sayıda çalışma yapılmıştır. Bu çalışmanın amacı imalat sanayi sektöründe faaliyet gösteren işletmelerin finansal başarısızlık durumlarının ortaya çıkmadan 1 yıl önceden tahmin edebilmesidir. Çalışmaya konu işletmelerin finansal başarı durumunun öngörülmesi için, işletmelerin bilanço ve gelir tablolarından hesaplanan, 9 adet finansal rasyo kullanılmıştır. Yapay sinir ağları ile oluşturulan modelde, 100 adet imalat firmasından 50 tanesi yapay sinir ağının eğitilmesi amacıyla deney grubu, 50 tanesi ise modelin test edilmesi amacıyla test grubu olarak ayrılmıştır. Yapılan denemeler sonucunda oluşturulan çok katmanlı algılayıcı (MLP) yapay sinir ağı modeli, test grubuna dâhil işletmelerin 1 yıl sonraki finansal durumlarını %94 tahmin gücü ile başarıyla sınıflandırmıştır.

Anahtar Kelimeler: Finansal başarısızlık, yapay sinir ağları, finansal rasyolar, erken uyarı sistemleri

SUMMARY

In literature, so many studies have been made on the financial failure. Main purpose of this study is that multilayer perceptron neural network model (MLP) is able foresee the plight of the companies running on manufacturing industry a year before they have experienced the financial failure. To predict the financial achievement of the the firms on which this study as conducted, nine financial ratios have been used from balance sheets and income statement reports. In a model of neural network, fifty companies were subjected to training as an experimental group for neural network, while another fifty out of hundred companies were designed as an test group to check the success of the model. Accuracy of the developed model was found 94%. The model of multilayer perceptron (MLP) neural network made up of results of the conducted experiments could successfully predict the financial plight of the companies for the following year included in test groups.

Keywords: Financial failure, neural network, financial ratios, early warning systems

TEŞEKKÜR

Tez çalışmam süresince desteğini ve hoşgörüsünü esirgemeyen değerli danışman hocam Prof. Dr. Muzaffer KAPANOĞLU'na ve desteklerini esirgemeyen aileme ve çalışma arkadaşlarıma teşekkürlerimi sunarım.

Ercan AKDENİZ

İÇİNDEKİLER

Sayfa

ÖZET	vi
SUMMARY	vii
TEŞEKKÜR	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ	xiii
1. GİRİŞ VE AMAÇ	1
2. LİTERATÜR ARAŞTIRMASI	3
3. KREDİ VE RİSK KAVRAMI	9
3.1 Kredi Tanımı	9
3.2 Kredi Riski	10
3.3 Kredi Riskinin Ölçülmesi	11
3.4 Sorunlu Krediler ve Karşılıklar Kararnamesi	12
3.5 Sorunlu Kredilerin Bankalara Maliyeti	14
4. FİNANSAL BAŞARISIZLIK VE ÖNGÖRÜLMESİ	17
4.1 Finansal Başarısızlığın Tanımı	17
4.2 Finansal Başarısızlığın Nedenleri	18
4.3 Finansal Başarısızlık Tahminin Kredi Kararlarına Katkısı	19
5. YAPAY SİNİR AĞLARI	21
5.1 Yapay Sinir Ağları Tanımı	21
5.2 Yapay Sinir Ağları Yapısı ve Elemanları	22
5.3 Yapay Sinir Ağlarında Sınıflandırma	24
5.3.1 Mimari Yapılarına Göre Yapay Sinir Ağları	24
5.3.1.1 İleri beslemeli yapay ağlar	24
5.3.1.2 Geri beslemeli ağlar	24

İÇİNDEKİLER (devam)

5.3.2 Öğrenme Yapılarına Göre Yapay Sinir Ağları	24
5.3.2.1 <u>Danışmanlı (denetimli) öğrenme</u>	25
5.3.2.2 <u>Danışmansız (denetimsiz) öğrenme</u>	26
5.3.2.3 <u>Takviyeli (pekiştirerek) öğrenme</u>	26
5.4 Yapay Sinir Ağlarının Avantajları ve Dezavantajları	28
5.4.1 Yapay sinir ağlarının avantajları	28
5.4.2 Yapay sinir ağlarının dezavantajları	28
6. MATERİYAL VE YÖNTEM	30
6.1 Firma Seçimi	30
6.2 Değişken (Finansal rasyo) Seçimi	31
6.2.1 Likidite oranları	31
6.2.1.1 <u>Cari oran</u>	32
6.2.1.2 <u>Likit oran (asit-test oranı)</u>	32
6.2.2 Mali yapı oranları	33
6.2.2.1 <u>Toplam borçlar / aktif toplamı (finansal kaldıraç oranı)</u>	33
6.2.2.2 <u>Öz kaynaklar / aktif toplamı</u>	33
6.2.3 Faaliyet oranları	34
6.2.4 Kârlılık oranları	34
6.2.4.1 <u>Brüt satış kârı oranı (brüt kâr marjı)</u>	35
6.2.4.2 <u>Net kâr marjı oranı (net kâr marjı)</u>	35
6.2.4.3 <u>Öz kaynak (öz sermaye) kârlılık oranı</u>	35
6.2.4.5 <u>Favök (ebitda) marjı</u>	35
6.3 Yöntem	36
6.3.1 Yapay sinir ağı modeli	36
6.3.2 Lojistik regresyon modeli	38
7. BULGULAR VE TARTIŞMA	41
8. SONUÇ VE ÖNERİLER	47
KAYNAKLAR DİZİNİ	50

ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
3.1 Mart 2018 itibarıyla sektör bazında ticari krediler	15
5.1 Sinir sisteminin blok diyagramı	22
5.2. Yapay sinir hücresi	22
5.3 Yapay sinir ağı katmanlarının birbirleri ile ilişkisi	23
7.1 En iyi sonucu veren 9-5-1 MLP ağ yapısı, YSA model görünümü	41
7.2 Deney grubu plot regresyon sonuçları	44

ÇİZELGELER DİZİNİ

<u>Cizelge</u>	<u>Sayfa</u>
2.1 Yapay sinir ağları ile iflas tahmini modellerinin sınıflandırma başarı oranları	7
3.1 Kredi riskinin kaynakları	11
3.2 Düzenleyici otoriteler tarafından yapılan kredi tasnifi	13
4.1 Finansal başarısızlık ve iflas tanımları	18
4.2 Finansal başarısızlık tahmininde kullanılan oranlar	19
5.1 Öğrenme algoritmaları ve uygulandıkları alanlar	27
5.2 Kullanım amaçlarına göre YSA topolojileri	27
6.1 Lojistik regresyon modelinde yer alan bağımsız değişkenler tablosu	39
6.2 Lojistik regresyon modeli omnibus testi sonuçları	39
6.3 Lojistik regresyon model özeti	40
6.4 Lojistik regresyon modeli değişkenleri	41
7.1 En uygun YSA modelini belirlemek için yapılan denemeler	42
7.2 Giriş nöronları ile gizli katman nöronları arasındaki ağırlık değerleri	43
7.3 Gizli katmandaki nöronların eşik değerleri	43
7.4 Gizli katmandaki nöronlar ile çıkış katmanındaki nöronlar arasındaki ağırlık değerleri.....	44
7.5 Çıktı katmanındaki nöronun eşik değeri	45
7.6 Yapay sinir ağı modeli sınıflandırma tablosu	45
7.7 Lojistik regresyon analizi sınıflandırma tablosu	46

SİMGELER ve KISALTMALAR DİZİNİ**Kısaltmalar****Açıklama**

BDDK	Bankacılık Düzenleme ve Denetleme Kurumu
İİK	İcra İflas Kanun
LM	Levenberg-Marquart algoritması
MLP	Çok katmanlı algılayıcı yapay sinir ağı
MSE	En küçük hata kareleri ortalaması
R^2	Determinasyon katsayısı
TBB	Türkiye Bankalar Birliği
TTK	Türk Ticaret Kanunu
TMSF	Tasarruf Mevduatı Sigorta Fonu
YSA	Yapay sinir ağıları

1. GİRİŞ VE AMAÇ

Bu çalışmada imalat sanayi sektöründe faaliyet gösteren işletmelerin finansal rasyolarının kullanılarak finansal başarısızlıklarının bir yıl önceden tahmin edilmesi amaçlanmıştır. İmalat, ticaret veya hizmet vb. gibi farklı sektörlerde faaliyet gösteren işletmelerin finansal rasyolarının sektör içinde benzeşmesi ve diğer sektörlerle nazaran belirgin farklılıklar içermesinden dolayı çalışmada örnek alınan işletmelerin hepsi, farklı sanayi kollarında faaliyet gösterebilirler bile alanlarında imalat yapan işletmeler arasından seçilmişlerdir.

Finansal başarısızlık kavramı ile ilgili literatürde ve yapılan çalışmalarda çok farklı içeriği olan tanımlar mevcuttur. Burada asıl olan finansal başarısızlık hakkında mutlak bir tanım olmaması değil, yapılan tanımların içerdiği varsayımlardır. Bu tanımlara ve varsayımlara çalışmanın dördüncü bölümünde detaylı olarak yer verilmiştir. Bu çalışmada finansal başarısız olarak görülen işletmeler bankalara olan borçlarında ödemeleri 91 gün ve üzeri aksamış, bankalar tarafından tahsil imkânı sınırlı alacak olarak sınıflandırılmış ve idari takibe aktarılmış firmalar tanımlanmıştır.

İşletmelerin finansal başarısızlığa uğrama nedenleri arasında işletme için nedenlerin yanı sıra, genel ekonomik aktivite ve çevresel faktörler de yer alsa bilse bu faktörlerin önceden tahmin edilmesindeki güçlükler nedeniyle bugüne kadar literatürde yapılan çalışmalarda ağırlıklı olarak işletme için nedenleri matematiksek olarak en kolay şekilde ifade edebilen finansal rasyolardan yararlanılmıştır.

Finansal rasyo seçiminde, literatürde konu hakkında yapılan çalışmalarda hangi rasyoların kullanıldığı da araştırılmakla beraber, ülkemizin şartları, firmalar tarafından sıklıkla başvuru bilanço makyajlamaları da dikkate alınarak 9 adet rasyo seçimi yapılmıştır.

Bu bilgiler dâhilinde yapay zekâ teknikleri arasında yer alan, makine öğrenmesine örnek olarak gösterilebilecek tekniklerden olan yapay sinir ağları ile imalat sanayi

sektöründe faaliyet gösteren işletmelerin finansal başarısızlık durumlarının bir yıl öncesinden tahmin edilmeye çalışılmıştır.

Yapılan yapay sinir ağı modeli denemeleri sonucunda tek gizli katmanı bulunan ve bu katmanda 5 nöron yer alan, Levenberg-Marquardt algoritması ile eğitilmiş çok katmanlı algılayıcı yapay sinir ağı modeli %94 tahmin gücü ile en iyi sınıflandırmayı yapan model olarak bulunmuştur.



2. LİTERATÜR ARAŞTIRMASI

2.1 Finansal Başarısızlık Literatür Araştırması

Altman, 1968, bu çalışmasında çoklu diskriminant analizini kullanarak iflas edecek işletmelerin birkaç yıl öncesinden öngörülebilmesi üzerine bir model ortaya koymuştur. Çalışmada 33 iflas etmiş ve 33 iflas etmemiş olmak üzere 66 işletme konu alınarak, bu işletmelere ait 5 finansal oran (22 finansal oran arasından istatistiksel analizler sonucu 5 finansal oran tercih edilmiştir) oluşturulan modelde kullanılmıştır. Altman oluşturduğu modele “Z (Zeta)” modeli adı vermiş olup, bu tarihten sonraki birçok çalışmada bu model temel alınmıştır. Altman Z modeli ile yaptığı çalışmasında işletmeleri iflastan bir yıl öncesi için %95, iki yıl öncesi için %72, 3 yıl öncesi için %48, 4 yıl öncesi için %29 ve 5 yıl öncesi için %36 oranında doğru sınıflandırabilmiştir.

Beaver, 1966, çalışmasında 1954-1964 yılları arasında faaliyet göstermiş 79’u finansal başarısızlığa uğramış, 79’u ise finansal açıdan başarılı 158 firmanın finansal rasyolarını 6 grupta toplamış ve bir gruptan sadece bir finansal rasyoyu çalışmasında dâhil etmiştir. Çalışma sonucunda finansal başarısızlığa uğramış ve finansal açıdan başarılı firmaları ayırt etmede en başarılı oranın Nakit Akışı/Toplam Borç oranı olduğunu ortaya konmuştur. Nakit Akışı / Toplam Borç oranı, finansal başarısızlığı bir yıl öncesinden %87, iki yıl öncesinden %79, üç yıl öncesinden %77, dört yıl öncesinden %76 ve beş yıl önceden %78 oranında doğru tahmin etmiştir.

Tamari, 1966, bu çalışmasında 28’i iflas etmiş, 28’i finansal açıdan başarılı toplam 56 İsrail endüstri firmasının, 6 farklı finansal rasyosunu kullanmış ve finansal durumu kötü olan işletmelerin finansal rasyolarının beş yıl öncesinden, faaliyette bulunduğu sektörün ortalama rasyolarından olumsuz anlamda ayrılmaya başladığını, bu ayrışmanın iflas dönemine yaklaştıkça giderek arttığını tespit etmiştir.

2.2 Yapay Sinir Ağları ile Finansal Başarısızlık Literatür Araştırması

Aktaş vd., 2003, bu makalede finansal başarısızlık tahmini üzerine Borsa İstanbul'da 1983-1987 yıllarında faaliyet göstermiş 53'ü finansal açıdan başarısız, 53'ü başarılı olmak üzere toplam 106 firma üzerinde bir çalışma yapmışlardır. Finansal başarısız firmaların seçiminde aşağıda yer alan 7 kıstas temel alınmıştır;

- İflas,
- İşletmenin sermayesinin %50'sini kaybetmesi (dönem ve geçmiş yıllar zararlarının toplamının sermayesinin %50'sini aşması),
- İşletmenin aktif toplamının %10'unu kaybetmiş olması (dönem ve geçmiş yıllar zararlarının aktif toplamının %10'unu bulması),
- İşletmenin üç yıl art arda zarar etmesi,
- İşletmenin borçlarını ödemekte zorlanması,
- Üretim faaliyetlerini durduracak ölçüde finansal problem yaşanması,
- İşletmenin borçlarının, aktif toplamını aşması.

Yukarıda yer alan kriterlerden herhangi birine uymayan firmalar ise finansal açıdan başarı firma olarak değerlendirilmiştir. Çalışmada veri seti oluşturulurken değişken olarak firmaların bilançolarında hesaplanan finansal oranlar kullanılmıştır. Çalışmada çoklu regresyon, diskriminant ve logit analizlerinin performansları ile öğrenme algoritması olarak Jacob'un Geliştirilmiş Geri Yayılım Algoritması'nın kullanıldığı yapay sinir ağları ile karşılaştırmıştır. Analizler sonucunda yapay sinir ağlarının finansal başarısızlık tahminindeki başarısının istatistiksel yöntemlere oranla daha yüksek olduğu görülmüştür.

Kurtaran Çelik, 2010, bu makalede bankaların finansal başarısızlıklarının tahmin edilmesine yönelik erken uyarı modelleri oluşturmaya amaçlamıştır. Türkiye'de faaliyet göstermiş 36 adet özel sermayeli bankanın konu edinildiği çalışmada, bankaların finansal başarısızlık durumuyla karşılaşma olasılıkları bir ve iki yıl öncesinden ayrı ayrı tahmin edilmeye çalışılmıştır. Bir yıl önceden başarılı veya zarar eden bankaların sınıflandırılmasında en doğru tahmin %100 oranında tahmin başarısı ile yapay sinir ağları

modeline ait iken, iki yıl önceden başarılı veya zarar eden bankaların sınıflandırılmasında en iyi modelin %91,7 tahmin başarısı ile diskriminant analizi olduğu ortaya konulmuştur.

Odom ve Sharda, 1990, yılında yaptıkları çalışma, iflas tahmini üzerine yapay sinir ağları ile yapılan ilk çalışmalardandır. 1975-1982 yılları arasında 65 iflas etmiş, 64 iflas etmemiş olmak üzere toplam 129 işletmenin konu edildiği çalışmada, 3 katmanlı ileri beslemeli yapay sinir ağır modeli ile çok değişkenli diskriminant analizi modelinin firmaları doğru sınıflandırma performansı karşılaştırılmıştır. Sonuç olarak yapay sinir ağı modelinin iflas etmiş firmaların tahmininde daha başarılı olduğu görülmüştür.

Benli, 2005, yılında bankaların finansal başarısızlıklarının öngörülmesini hedefleyen çalışmada lojistik regresyon ve yapay sinir ağı modellerini karşılaştırmıştır. Çalışmada 1997-2001 yılları arasında TMSF'ye (Tasarruf Mevduatı Sigorta Fonu) devredilen 17 özel sermayeli ticaret bankası ile faaliyetlerini sürdüren 21 özel sermayeli ticaret bankası incelenerek söz konusu bankaların 12 finansal rasyosu baz alınmış ve bu bankaların bir yıl öncesinden finansal başarısızlıklarının öngörülmesi amaçlanmıştır. Yapay sinir ağı modelinin başarısız bankaları doğru tahmin etme gücü % 82,4, lojistik regresyon modelinin ise % 76,5 olarak bulunmuştur. Yapay sinir ağı modelinin lojistik regresyon modelinden daha yüksek doğru sınıflandırma yaptığı, bu nedenle bankalar için yapılacak finansal başarısızlık tahmin çalışmalarında yapay sinir ağlarının da kullanılabileceği belirtilmiştir.

Shin ve Lee, 2002, yılında işletmelerin finansal başarısızlıkların öngörülmesi üzerine çalışmada 264 tanesi finansal açıdan başarılı, 264 tanesi finansal açıdan başarısız olmak üzere 528 orta ölçekli imalat firması üzerinde çalışmışlardır. Firma bilançolarından elde edilen 9 finansal rasyonun veri olarak kullanıldığı çalışmada çoklu diskriminant analizi, logit ve probit gibi istatistiksel tekniklerin yanı sıra yapay sinir ağları ve genetik algoritma teknikleri de kullanılmıştır. İflas tahmininde genetik algoritmaların da kullanılabileceği belirtilen söz konusu çalışmada genetik algoritmaların uzman sistemlerde olduğu gibi daha anlaşılabilir sonuçlar ürettiği vurgulanmıştır.

Alfaro vd., 2008, 590 sağlıklı, 590 iflas etmiş firmayı konu alan çalışmada yapay sinir ağları ve bir sınıflandırma tekniği olan Adaboost tekniğini karşılaştırmıştır. Son yıllarda

kurumsal başarısızlık tahmini için sıklıkla kullanılan ve doğrusal olmayan problemlerin çözümünde daha başarılı olduğu bilinen yapay sinir ağlarının adaboost tekniğine kıyasla finansal başarısızlık tahmininde %30 daha başarılı olduğunu öne sürmüştür.

Nguyen, 2005, bu çalışmasında çok katmanlı yapay sinir ağları, olasılıklı yapay sinir ağları ve lojistik modellerinin işletmelerin finansal başarısızlığını 1 ve ya 2 yıl öncesinden tahmin etme gücünü araştırmıştır. Çalışmada veri olarak işletmelerin bilançolarından elde edilen finansal rasyolar kullanılmıştır. Üç modelinde işletmelerin finansal başarısızlığı öngörüsünde doğru tahminler yaptığı belirtilmekle birlikte, olasılıklı yapay sinir ağlarının hem 1 yıl hem de 2 yıl önceden finansal başarısızlığın öngörülmesi konusunda diğer iki modele göre daha doğru tahminler yapabildiği belirtilmiştir.

Jo ve Han, 1997, yılında yaptıkları çalışmada Güney Kore'deki 1991-1993 yılları arasında faaliyet göstermiş, 271 iflas etmiş ve 271 iflas etmemiş olmak üzere toplam 542 firmaya ait verileri kullanmışlardır. Çalışmada, yapay sinir ağları, diskriminant analizi ve kural tabanlı uzman sistem yöntemleri kullanılmıştır. Diskriminant analizinin %82,22, yapay sinir ağlarının %83,79 ve kural tabanlı uzman sistemin %81,52 oranında doğru sınıflandırma yapabildiği görülmüştür. Yapay sinir ağlarının tahmin gücünün diğer modellerden istatistiksel olarak daha başarılı olduğu saptanmıştır.

Rudorfer, 1995, yapay sinir ağlarını kullanarak firma iflaslarının önceden tahmin edilmesini konu alan çalışmasında, 59 tanesi sağlıklı, 23 tanesi iflas etmiş olmak üzere toplam 82 firma verisi üzerinde çalışmıştır. Veri olarak söz konusu firmaların bilançolarından 5 tane rasyoyu kullanarak firmaların iflas etme olasılığını önceden tahmin etmeye çalışmıştır. Çalışmada kullanılan rasyolar şunlardır: nakit akışı / pasif, cari oran, dönen varlıklar / aktif toplamı, yabancı kaynaklar (Toplam Borçlar) / aktif toplamı ve kar-zarar / aktif toplamı (Ruforfer, 1995).

Du Juardin P., 2010, yılında yaptığı çalışmasında yapay sinir ağları yöntemi ile yapılan iflas tahmini çalışmalarının başarı oranlarını derlemiş olup, bu oranlara Çizelge 2.1'de yer verilmiştir (Du Jardin, 2010).

Çizelge 2.1 Yapay sinir ağları ile iflas tahmini modellerinin sınıflandırma başarı oranları

Yazar	İflas etmemiş firmaların doğru sınıflandırılma oranı	İflas etmemiş firmaların doğru sınıflandırma oranı	Toplam doğru sınıflandırma oranı
Agarwal	99,00%	93,70%	96,38%
Alfaro vd	92,37%	82,20%	87,29%
Altman vd.	89,40%	86,20%	87,80%
Anandarajan vd.	93,75%	95,45%	95,19%
Back vd.	100,00%	98,00%	99,00%
Back vd.	100,00%	94,25%	97,30%
Back vd.	100,00%	94,40%	97,30%
Bell vd.	97,70%	61,80%	94,00%
Berg	?	69,50%	?
Boritz ve Kennedy	84,03%	84,27%	?
Bose and Pal	75,62%	68,21%	71,88%
Boyacıoğlu vd.	?	?	95,50%
Brabazon ve Keenan	82,67%	78,67%	80,67%
Brockett vd.	94,50%	73,30%	89,30%
Charalambous vd.	84,21%	84,21%	84,21%
Charitou vd.	76,19%	90,48%	83,33%
Dorsey vd.	?	?	?
Etheridge and Sriram	92,71%	100,00%	92,85%
Fan ve Palaniswami	?	?	66,11%
Fanning ve Cogger	76,00%	94,00%	85,00%
Goss ve Ramchandami	75,00%	75,00%	75,00%
Huang vd.	?	?	?
Jo vd.	?	?	83,79%
Kim ve Mcleod	?	?	78,70%
Kiviluoto	88,30%	69,50%	86,50%
Kotsiantis vd.	?	?	71,17%
Kumar vd.	?	?	69,73%
Lacher vd.	97,20%	91,50%	94,70%
Laitinen ve Kankaanpaa	89,50%	84,20%	86,80%
Lee vd.	?	?	80,48%
Lee vd.	76,19%	95,24%	85,22%
Leshno ve Spector	91,00%	90,90%	90,05%
Li ve Gupta	?	?	78,15%
Mckee ve Greenstein	86,00%	75,00%	86,00%
Min vd.	?	?	75,96%
Min ve Lee	85,71%	79,36%	82,54%

Çizelge 2.1 Yapay sinir ağıları ile iflas tahmini modellerinin sınıflandırma başarı oranları
(devam)

Yazar	İflas etmemiş firmaların doğru sınıflandırılma oranı	İflas etmemiş firmaların doğru sınıflandırma oranı	Toplam doğru sınıflandırma oranı
Min ve Lee	?	?	71,72%
Odom ve Sharda	?	?	81,81%
Pendharkar	?	?	?
Piramuthu vd.	92,70%	85,40%	89,10%
Pompe ve Feelders	?	?	72,60%
Salchenberger vd.	90,00%	96,00%	92,50%
Sen vd.	?	?	?
Serrano-Cinca	?	?	93,94%
Sexton vd.	97,40%	95,65%	?
Shin ve Lee	?	?	74,10%
Tam ve Kiang	85,00%	89,00%	87,00%
Tam ve Dihardjo	92,35%	64,70%	92,23%
Tung vd.	99,31%	54,54%	73,12%
Tyree ve Long	100,00%	94,55%	97,95%
Vieira vd.	?	?	90,00%
Wallrafen vd.	?	?	?
West vd.	?	?	87,27%
Wilson ve Sharda	98,00%	97,50%	97,75%
Wu vd.	99,40%	83,30%	?
Yang ve Harrison	95,50%	92,37%	95,27%
Yang vd.	90,00%	63,00%	84,00%
Yim ve Mitchell	94,00%	80,00%	90,96%
Yim ve Mitchell	100,00%	89,00%	96,55%

Çizelge 2.1’de doğru sınıflandırma oraları arasında yer alan “?” çalışmada söz konusu sınıflandırma oranı (tahmin gücü) hakkında bilgi verilmediğin ifade etmektedir.

3. KREDİ VE RİSK KAVRAMI

3.1 Kredi Tanımı

Kredinin sözlük anlamı itibardır. Bir mevcudun (nakdi veya gayrinakdi bir itibarın) belli bir süre için (vade) ve geri alınmak kaydıyla, bir bedel (faiz, komisyon vs.) karşılığında gerçek yada tüzel kişiler lehine verilmesi (ödünç para verme-nakdi kredi) veya verilmiş bir varlığın geri ödenmesinin ya da bir hizmet taahhüdünün garanti edilmesidir (gayrinakdi kredi). Kredi, tanımı gereği üç temel unsur içerir. Vade, güven ve risk.

Vade: verilen ödünç belirli bir süre sonra geri alınacağından veya verilen garanti belirli bir süre için geçerli olacağı için kredide vade önemli unsurlardan biridir. Zaman içerisinde genel ekonomik durumdaki değişimler, sektördeki gelişmeler veya kredi müşterisinin karşılaşılabileceği özel durumlar, belirsizlikler içerdiği için vade uzadıkça risk artar.

Güven: Kredi güvene dayalı bir işlemdir. Taraflar arasında karşılıklı yükümlülükleri zamanında yerine getireceğine / getirebileceğine dair güven ilişkisinin oluşması gerekir.

Risk: Kredi işlemi tanımı gereği risk içerir. Kredi sürecinde yapılan araştırma, değerlendirme ve teminatlandırma ile riskin minimize edilmesi amaçlanır.

Kredilerin tahsis aşaması ve daha sonraki süreçlerde dikkat edilen temel ilkeler güvenilirlik, seyyaliyet ve verimliliklerdir. Bu ilkeleri kısaca açıklamak gerekirse:

Güvenilirlik (emniyet): Kredinin sağlamlığı, yeterli düzeyde teminatlandırmış olması, kredi müşterisi hakkında yeterli araştırmanın yapılarak kredibilitesinin tespit edilmiş olması gerekir.

Seyyaliyet (akışkanlık): Kredinin dolu ve donuk bırakılmaması, orijinal vadesinde geri ödenmesidir. Müşteri özelinde uygun kredi türü tespiti yapılması, firmalara ihtiyacının

üzerinde kredi tesis edilmemesi ve alınan kredinin amacına uygun olarak kullanılması akışkanlığı sağlar.

Verimlilik: Kredi ilişkisine girilen müşterinin ihtiyaçlarının doğru tespit edilerek faiz dışı gelirlerin elde edilmesi kredilerin verimliliğini arttıran en önemli unsurdur.

3.2 Kredi Riski

Kredi riski, kredilendirilen müşterinin, kredi borcunun vadesinden önce kredi kalitesinin bozulması veya borç vadesinde sözleşme şartlarına aykırı olarak yükümlülüklerini kısmen veya tamamen zamanında yerine getirememesi nedeniyle bankanın karşılaştığı zarar etme durumudur. Bankalar ve finans kurumları kredilendirme sürecinden başlayıp tahsil sürecine kadar birçok farklı sebepten ötürü kredi riski ile karşılaşabilirler. Hatalı müşteri seçimi, işletmenin kaldırabileceğinden fazla limit tahsisi, kredi sözleşmelerindeki yanlışlıklar ve eksiklikler, müşterinin finansal gücünün kredi yükümlülüklerini yerine getirecek kadar iyi olmaması, krediye uygun teminat seçimi yapılmaması veya eksik teminatlandırma ve genel ekonomik faktörler kredi riskini doğuran temel etmenlerdir (Mirza, 2006).

Bankaların sağlıklı bir şekilde faaliyetlerini sürdürebilmeleri için, gelir yaratıcı eylemlerin yanı sıra, giderlerini azaltan önlemler almaları gerekmektedir. Risk bankacılığın önlenemeyen ve giderilemeyen bir unsurudur. Fakat riski başarılı şekilde yönetmek mümkündür. Bankacılık sektöründe dört temel risk türü vardır. Bunlar; kredi riski, faiz oranı riski, likidite (fonlama) riski ve ekonomik risktir.

Bu risk türlerinden kredi riski kabul edilebilir fakat istenmeyen bir risk türüdür. Kredi tahsis edildikten sonra her zaman kredinin gereken miktarda veya zamanında tahsil edilememe riski vardır. Kredi riski; mali tahlil birimleri, kredi tahsis birimleri ve risk tahsil ve tasfiye birimlerinin dikkatli ve koordineli bir çalışma sürdürmesiyle en aza indirilebilir (Seval, 1990). Bankaların karşılaştığı en önemli finansal risk kredi riskidir ve bankaların kredi riskini yönetme becerileri gelecekteki performansı için önemli bir göstergedir. Bankacılığın risk alma sanatı olduğu ve kalbinde kredi riskinin yer aldığı düşünülecek

olursa, kredi riskinin sağlıklı bir şekilde analiz edilmesinin bankalar için önemi büyüktür (Sonbul İskender, 2014).

Kredi riski kaynakları içsel ve dışsal faktörler olarak sınıflandırılabilir. Söz konusu sınıflandırma ve detaylarına ilişkin bilgilere aşağıdaki tabloda yer verilmiştir. Kredi riskinin kaynakları Çizelge 3.1’de verilmiştir. (Sonbul İskender, 2014).

Çizelge 3.1 Kredi riskinin kaynakları

İÇSEL FAKTÖRLER	DIŞSAL FAKTÖRLER
1) Kredi Müşterisine Özgü Faktörler	1) Politik, ekonomik, sosyal faktörler
Tedarik, üretim ve pazarlama yapısı Rekabet gücü Yönetim becerisi	Yasal düzenleme değişiklikleri, Politik yapıdaki değişiklikler, Ekonomi politikalarındaki değişiklikler, Oynaklık, şok ve krizler
2) Bankaya Özgü Faktörler	2) Doğal Faktörler
Mali Tahlil – İstihbarat yapısı Risk değerlendirme kabiliyeti Karar alma kriterleri Risk – Teminat dengesi	Doğa afetler, kuraklık vs.
3) Diğer Faktörler	3) Diğer Faktörler
Ürün yaşam döngüsü	Teknolojik gelişmeler, Müşteri tercihleri

3.3 Kredi Riskinin Ölçülmesi

Bankacılıkta risk yönetiminin amacı bankanın risk almasını engellemek değildir. Risk yönetiminin amacı; bankanın mali performansını arttırmak, tolere etmekte zorlanacağı zararların ortaya çıkmasını engellemek ve bankanın karşılaşılabileceği riskleri yöneterek, bankanın risk ayarlı getirisini en üst düzeye çıkarmaktır (Bakır Yiğitbaş, 2012).

Bir erken uyarı sinyali olarak kullanılan kredi riskinin ölçümü çalışmaları her zaman kesin doğru sonuçlar vermese de bankalar ve kredi tahsis uzmanları için önemli bir gösterge olmuştur. Bu nedenle her geçen gün gerek literatürde konu üzerinde yapılan çalışmalar ve

geliştirilen modellerin sayısı giderek artmakta gerekse bankalar tarafından oluşturulan kredi skor modellerinde temerrüt ve iflas olasılığına ilişkin tahmin modelleri daha fazla yer almaktadır.

3.4 Sorunlu Krediler ve Karşılıklar Kararnamesi

Banka müşterisinin kredi kullanması ve kredi riskinin doğmasından sonra üç olay meydana gelebilir. Bunlardan birincisi, kredinin sözleşme şartları dâhilinde sorunsuzca tahsil edilmesidir. İkincisi, kredi şartları ve kredi ödeme planının yeniden yapılandırılması durumudur. Üçüncüsü ise kredinin tahsil edilememesi ve bir sorunlu kredinin ortaya çıkması durumudur (Polat, 1995).

Bankalar tarafından verilen kredilerin, tahsil kabiliyeti ve borçlunun kredibilitesine göre sınıflandırılması ve bu sınıfta yer alan krediler için ayrılması gereken genel ve özel karşılık oranları BDDK (Bankacılık Düzenleme ve Denetleme Kurumu) tarafından çıkartılan karşılıklar kararnamesi ile belirlenmiştir. Bu kararnameye göre;

Birinci grup - standart nitelikli krediler ve diğer alacaklar: Ödemeleri zamanında yapılan ve gelecekte de geri ödeme problemi beklenmeyen krediler bu sınıfta yer alır. Bankalar bu sınıfta yer alan nakdi kredileri toplamının yüzde biri (% 1), gayrinakdi kredileri toplamının binde ikisi (% 0,2) oranında genel karşılık ayırırlar.

İkinci grup - yakın izlemedeki krediler ve diğer alacaklar: Bu grupta geri ödenmesi kuvvetle muhtemel olmakla birlikte kredi ödemelerinde 31 ve 90 gün dâhil bu süreler arasında gecikme yaşanan krediler bu sınıfta yer alır. Bankalar bu grupta yer alan nakdi kredileri toplamının yüzde ikisi (% 2), gayrinakdi kredi toplamının binde dördü (% 0,4) oranında genel karşılık ayırırlar.

Üçüncü grup - tahsil imkânı sınırlı krediler ve diğer alacaklar: Kredi geri ödemelerinde 91 ve 180 gün dâhil bu süreler arasında gecikme yaşanan krediler bu sınıfta yer alır. Bankalar, üçüncü gruba ayırdığı kredilerle ilgili olarak en az yüzde yirmi (% 20), oranında özel karşılık ayırırlar.

Dördüncü grup - tahsili şüpheli krediler ve diğer alacaklar: Kredi geri ödemelerinde 181 gün ve 1 yıl arasında gecikme yaşanan krediler bu grupta sınıflandırılır. Bankalar, dördüncü gruba ayırdıkları kredilerle ilgili olarak en az yüzde elli (% 50), oranında özel karşılık ayırırlar.

Beşinci grup - zarar niteliğindeki krediler ve diğer alacaklar: Tahsili bir yıldan fazla gecikmiş olan krediler bu grupta sınıflandırılır. Bankalar, beşinci grupta sınıflandırdıkları kredilerle ilgili olarak en az yüzde yüz (% 100), oranında özel karşılık ayırırlar (BDDK, 2017).

Kredilerin sürekli olarak izlenmesi ve değerlendirmeye tabi tutulması uluslararası alanda kabul görmüş bir kuraldır. Bankacılık sisteminin en eski derecelendirme sistemlerinden birisi olan The Office of the Comptroller of the Currency (OCC) tarafından geliştirilen ve daha sonra dünyanın pek çok ülkesinde kullanılan karşılık ayırmada esas alınan tabloya Çizelge 3.2’de yer verilmiştir (Çabukel, 2007).

Çizelge 3.2 Düzenleyici otoriteler tarafından yapılan kredi tasnifi

ABD de yer alan tasnif	Türk Bankacılık Sisteminde kullanılan tasnif	Özel Karşılık Oranı
Yüksek kalite derece		
Geçerli/canlı varlıklar (Pass/performing assets)	1. Grup – Standart Nitelikli Krediler ve Diğer Alacaklar	%0
Düşük kalite derece		
Özel dikkat gerektiren diğer varlıklar (Other assets especially mentioned – OAEM)	2. Grup - Yakın İzlemedeki Krediler ve Diğer Alacaklar	%0
Standart altı varlıklar (Sub-standard assets)	3. Grup – Tahsil İmkânı Sınırlı Krediler ve Diğer Alacaklar	%20
Şüpheli varlıklar (Doubtfull assets)	4. Grup – Tahsili Şüpheli Krediler ve Diğer Alacaklar	%50
Kayıp varlıklar (Loss assets)	5. Grup – Zarar Niteliğindeki Krediler ve Diğer Alacaklar	%100

3.5 Sorunlu Kredilerin Bankalara Maliyeti

Bankalar ve finans kuruluşları ile borçlu arasındaki geri ödeme sözleşmesinin önemli ölçüde ihlal edilerek kredi tahsilatlarının aksaması ve kreditorler için zarar ihtimalinin oluşması durumu, sorunlu kredi olarak tanımlanabilir. Sorunlu kredilerin daha fazla mali hasara yol açmadan tahsil edilmesi için bankanın ilgili risk izleme, risk tahsil ve tasfiye vb. birimlerinin söz konusu sorunlu kredi ve müşteri özelinde titizlikle çalışması gerekir. Banka bilançolarında sorunlu kredilere mutlaka yer alacaktır, önemli olan sorunlu kredilerin makul bir düzeyde tutabilmek ve bankayı olabildiğince zarardan korumaktır (Seval, 1990).

Sorunlu kredilerin kredi bankalar üzerindeki etkilerinden en önemlisi maliyet artışı ve potansiyel kâr kaybıdır. Bunun yanı sıra sorunlu kredilerin Banka bilançosundaki artışı bankanın da finansal anlamda zorluk yaşamasına sebebiyet verebilir. Sorunlu hale dönüşen ve dönüşmesi muhtemel krediler için bankaların yasal karşılık ve kaynak ayırması gerekir, bu da bankanın belirli maliyete katlanarak edindiği kaynakların alternatif maliyetini ve verimsizliğini arttırmaktadır. Bu durum, ekonomik açıdan ciddi bir kayıp demektir (Mirza, 2006).

Bankalar kredi tahsis ederken yüksek ve düşük risk algısı arasında makul bir orta yol bulmalıdır. Bir banka çok düşük düzeyde risk almayı tercih ederse pazar payını kaybedebilir. Bunun tam tersi olarak yüksek risk alınmak istenilmesi durumunda bu risklerin bankaya maliyeti şu şekilde özetlenebilir (Seval, 1990).


- Sorunlu kredilere ayrılan kaynaklar, daha iyi getiri elde etme imkânı sağlayabilecek alanlara yönlendirilemeyecektir.
- Sorunlu kredilerin izlenmesi ve tahsili süreci bankaya ilave operasyonel masraflar yükleyecektir.
- Bankanın imajına olumsuz etkisi olacak bu da bankanın büyümesini negatif yönde etkileyecektir.
- Sorunlu kredilerin takibi ve tahsilatı aşamaları ciddi miktarda operasyonel ve hukuki masrafa yol açacaktır.

- Sorunlu kredilerin yüksek oranda olması muhtemelen düşük karlılık ve sınırlı büyümeye neden olacak bu da banka çalışanlarının moral motivasyonunu olumsuz etkileyecektir.

Bölüm 3.4'te kredilerin ve diğer alacakların, BDDK tarafından yayımlanan karşılıklar kararnamesine göre, nasıl sınıflandırılacağına dair bilgiler aktarılmıştı. Söz konusu kararnameye göre üçüncü, dördüncü ve beşinci sınıfa ayrılan krediler risk merkezine tasfiye olunacak alacaklar koduyla bildirim yapılır.

TBB tarafından yayımlanan Risk Merkezi Aylık Bülteni Mart2018 sayısına göre Türkiye'de Mart 2018 itibarıyla bankalar ve banka dışı finansal kuruluşlar tarafından kullanılan toplam nakdi kredi miktarı yaklaşık 2.345 milyar TL, tasfiye olunacak alacaklar ise yaklaşık 72 milyar TL olarak gerçekleşmiştir.

2.345 milyar TL'lik nakdi kredi tutarının 545 milyar TL'si bireysel krediler, 1.800 milyar TL'si ticari kredilerden oluşmaktadır. Ticari kredilerin sektör bazında dağılımına Şekil 3.1'de yer verilmiştir (TBB, 2018).



Şekil 3.1 Mart 2018 itibarıyla sektör bazında ticari krediler (Milyar TL, pay, yüzde)

Şekil 3.1’de görüldüğü üzere tez çalışmamızın da konusunu teşkil eden imalat sanayi sektörü, toplam ticari krediler arasında 451 milyar TL ve %25 pay ile en yüksek payı alan sektör olmuştur.

Mart 2018 itibarıyla tasfiye olunacak alacak oranı en yüksek olan sektörler; %4,3 ile toptan ve perakende ticaret sektörü ve %3,4 ile imalat sanayi olmuştur (TBB, 2018). Bu oranlara göre imalat sanayi sektöründe yaklaşık olarak 15,3 milyar TL tutarında tasfiye olunacak nakdi kredi tutarı bulunmaktadır. Karşılıklar kararnamesinde göre üçüncü, dördüncü ve beşinci gruplarda sınıflandırılan alacaklara %20 ila %100 oranında özel karşılık ayrılması gerektiği düşünülecek olursa bu tutarın bankalara maliyeti operasyonel masraflar hariç 25 milyar TL gibi çok yüksek bir tutardır.

Tez çalışmamız içerisinde ülke ekonomisine zararı 25 milyar TL’yi geçen tasfiye olunacak kredilerin, kötü kredi sınıfına girmeden 1 yıl önce tespit eden bir model oluşturulmaya çalışılmıştır.

4. FİNANSAL BAŞARISIZLIK VE FİNANSAL BAŞARISIZLIK TAHMİNİ

4.1 Finansal Başarısızlık Tanımı

Mali başarısızlık olarak da adlandırılabilen finansal başarısızlık, işletmelerin yerine getirmesi gereken yükümlülüklerini, güçlkle yerine getirebilmesi veya tamamen yerine getirememesi olarak tanımlanabilir. Bir işletmenin finansal başarısızlığa uğraması durumunda, çalışanların motivasyonu bozulur ve kendilerini daha güvenli hissedebilecekleri işletmelere geçmek isterler. İşletmelerin mevcudiyetlerini sürdürebilmeleri borçlarını ve varlıklarını yönetebilme yeteneklerine bağlıdır (İçerli ve Akkaya, 2006).

Bir işletmenin alacakları borçlarından fazla olsa bile, alacakları ve borçları arasındaki vade uyumsuzluğundan ötürü nakit akışının bozulması ve finansal sorun yaşaması mümkündür. Genellikle bu durumun akıllıca bir finansal yönetimle aşılması mümkün olmakla birlikte, mali problemlerini çözemeyen işletmelerin iflasla sonuçlanan bir süreç yaşaması olasılıklar dâhilindedir.

İflas finansal başarısızlık kavramının en son evresi olarak adlandırılabilir. İflas kavramının tanımı, aynı zamanda hukuki bir terim olması nedeniyle ülkeler arasında farklılık gösterebilir. Ülkemizde iflas tanımı Türk Ticaret Kanunu (TTK) ve İcra İflas Kanun (İİK) çerçevesinde belirlenmiş olup, bir şirketin borçlarını ödeyemeyecek duruma düşmesi şeklinde tanımlanmıştır. Finansal başarısızlık kavramı, işletmenin yükümlülüklerini zamanında yerine getiremediği noktayla, işletmenin iflası arasındaki bu geniş alanı inceler. Çizelge 4.1’de finansal başarısızlık ve iflas tanımları hakkında literatürde geçen tanımlar tablo halinde sunulmuştur (Aktaş, 1993).

Çizelge 4.1 Finansal başarısızlık ve iflas tanımları

Yazar	Kullanılan Kavram	Tanım
Altman	İflas	Yasal olarak iflas etmiş ve kayyum atanmış ya da ulusal iflas yasası hükümlerine reorganizasyon hakkı verilmiş işletmeler.
Beaver	Finansal başarısızlık	Vadesi gelen finansal yükümlülükleri ödeyememe. Araştırma kapsamında finansal başarısızlık olarak şu olaylar alınmıştır: İflas, tahvil faizinin ödenememesi, karşılıksız çek yazılması, imtiyazlı hisse senetlerine temettü dağıtılmaması.
Blum	Finansal başarısızlık	Vadesi gelen borları ödeyememe, iflas sürecine girme, alacaklılarla borçların azaltılması konusunda açık anlaşma yapma.
Deakin	Finansal başarısızlık	İflas etmiş, ya da alacaklıların isteği üzerine tasfiye edilmiş işletme.
Edminster	Finansal başarısızlık	Hem Beaver hem de Blumun tanımları kullanılmıştır.
Elam	İflas	İflas yasası hükümlerine göre iflas etmiş sayılan işletmeler.
Taffler	İflas	Başarısızlık tasfiye, alacaklıların isteği üzerine tasfiye ve mahkeme kararıyla faaliyetine son vermek.

Finansal başarısızlığın işletme içi ve işletme dışı nedenlerden kaynaklandığı söylenilebilir. Bu etmenlerden işletme dışı etmenler olan enflasyon, ekonomik durgunluk, yoğun rekabet ortamı ülkemizde en çok şikâyet edilenleridir. İşletme içi etmen olarak ise serbest piyasa ekonomisine uyum sağlama konusunda işletme yönetimin yetersizliği dikkat çeken ve önemli finansal başarısızlık nedenlerindendir (Aktaş, 1993).

4.2 Finansal Başarısızlık Tahmininin Kredi Kararlarına Katkısı

Bankaların kredi taleplerini mantıklı bir biçimde değerlendirmesi ekonomik aktivitenin düzenli işleyişi açısından oldukça önemlidir. Bir bankanın, finansal başarısızlığa uğrama riski yüksek bir işletmeye risksizmiş gibi kredi limiti açması, ya da finansal

başarısızlık riski düşük olan sağlıklı bir işletmeye kredi limiti açmaması, kredi değerlendirmede karşılaşılan iki hatalı karar türüdür.

Birinci tür hata (finansal başarısızlığa uğrama riski yüksek bir işletmeye risksizmiş gibi kredi limiti tahsis edilmesi) banka için tahsili gecikmiş veya şüpheli alacakların artması sonucunu doğuracaktır. Bu sorunun büyümesi bankaları iflasa kadar sürükleyebilir. İkinci tür hata (sağlıklı bir işletmeye kredi limiti tahsis edilmemesi) kararı banka için fırsat maliyeti oluşturur. Bu tür kararlar bankanın kaynaklarının verimsiz kullanılmasına sebep olur (Aktaş, 1993).

4.3 Finansal Başarısızlık Tahmininde Finansal Oranların Kullanılması

Finansal başarısızlık tahmin çalışmalarında genellikle yalın bilanço verileri yerine finansal oranlar tercih edilmiştir. Finansal oranların kullanılmasının en büyük artısı, kar, ciro gibi işletmelerde rakamsal olarak büyük farklar içeren örneklerin aynı örnek, aynı model içerisinde incelenmesine imkân tanınmasıdır (Aktaş, 1993).

Çizelge 4.2’de Finansal başarısızlık tahmininde kullanılan oranlar tablo halinde sunulmuştur (Aktaş, 1993).

Çizelge 4.2 Finansal başarısızlık tahmininde kullanılan oranlar

	Blum	Beaver	Altman	Emdinster	Deakin	Taffler	El-Morris	Aktaş
Kasa / Kısa Vadeli Borçlar				X	X			
Nakit Akımı / Kısa Vadeli Borçlar				X				
Nakit Akımı / Aktif Toplamı							X	
Nakit Akımı / Toplam Borç	X	X			X			
Nakit / Net Satışlar					X			
Nakit / Aktif Toplamı					X			
Dönen Varlıklar / Kısa Vadeli Borçlar		X			X			
Dönen Varlıklar / Net Satışlar					X			
Dönen Varlıklar / Aktif Toplamı					X		X	
Kısa Vadeli Borçlar / Öz kaynak				X				
Öz kaynak / Net Satışlar				X				
Stoklar / Net Satışlar				X				

Çizelge 4.2 Finansal başarısızlık tahmininde kullanılan oranlar (devam)

	Blum	Beaver	Altman	Emdinster	Deakin	Taffler	El-Morris	Aktaş
Uzun Vadeli Borçlar / Net Sermaye							X	
Öz kaynağın Piyasa Değeri / Borçların Defter Değeri			X					
Net Dönem Karı / Aktif Toplamı		X			X			
Hazır Değerler / Stoklar	X							
Net Satışlar / Aktif Toplamı			X					
Net Değer / Toplam Yükümlülükler	X							
Faaliyet Karı / Aktif Toplamı			X			X		
Hazır Değerler / Kısa Vadeli Yükümlülükler					X		X	
Hazır Değerler / Net Satışlar					X			
Hazır Değerler / Aktif Toplamı					X	X	X	
Hisse Senedinin Getiri Oranı (Roe)								X
Dağıtılmayan Karlar / Aktif Toplamı			X					
Hisse Senedinin Getirisi						X		
Toplam Borçlar / Aktif Toplamı		X			X			X
Toplam Borçlar / Net Kullanılan Sermaye						X		

5.YAPAY SİNİR AĞLARI


5.1 Yapay Sinir Ağları Tanımı

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenmek suretiyle yeni bilgiler türetebilme, oluşturabilme ve keşfedebilme gibi yeteneklerini otomatik olarak gerçekleştirmek amacıyla geliştirilen bilgisayar tabanlı sistemlerdir. İnsan beyninin bu yeteneklerini geleneksel programlama yöntemleri ile gerçekleştirmek oldukça zor veya imkânsızdır. Bundan dolayı yapay sinir ağlarını, programlanması çok zor veya mümkün olmayan olaylar için geliştirilmiş bir bilgisayar bilimi olarak ifade edilebilir (Öztemel, 2016).

Yapay zekâ teknolojileri arasında sınıflandırılan yapay sinir ağları, insan beyninin özelliklerinden esinlenerek geliştirilmiş, çok değişkenli ve değişkenler arasında karmaşık ilişkilerin bulunduğu problemlerin çözümünde kullanılan bir bilgi işlem teknolojisidir (Bigus, 1996). İnsanoğluna özgü deneyerek öğrenme yeteneğini bilgisayar ortamına taşıyabildiği düşünülen yapay sinir ağları teknolojisi bir bilgisayar sistemine inanılmaz bir “girdi veriden öğrenme” kapasitesi sağlamaktadır. Çeşitli avantajlar sunan ve gün geçtikçe gelişen bu teknolojiden, günümüzde birçok alanda olduğu gibi ekonomi ve istatistik alanlarında da faydalanılmaktadır (Özdemir ve Bahadır, 2016).

5.2 Yapay Sinir Ağları Yapısı ve Elemanları

Yapay sinir ağlarının yapısını anlayabilmek için öncelikle insan beyninin yapısını ve çalışma şeklini anlamak gereklidir. İnsan beyni, sinir sisteminin merkezi olarak nitelendirilebilen ve aynı zamanda en temel elemanıdır. En yalın tarifle, sürekli olarak iletilen bilgiyi alır, işler ve karar vererek gerekli yerlere iletir. Basit gözüken fakat esasında karmaşık olan bu yapının Haykin (1999) tarafından basit bir gösterimi Şekil 5.1’de sunulmuştur (Yurtoğlu, 2005).




Şekil 5.1 Sinir sisteminin blok diyagramı

Şekil 5.1’de görüldüğü üzere, dışarıdan veya başka bir organdan gelen sinyaller (uyarı) alıcılar yoluyla sinir ağına iletilir. Sinir ağında işlenen sinyallerden çıktılar oluşturulur, bu çıktılar ileticiler vasıtasıyla dış ortama veya diğer organlara iletilir.

Yapay sinir ağlarının temel elemanları ise yapay nöronlardır. Bu nöronlar, aralarında bağlantılar oluşturularak ve tabakalar halinde gruplandırılarak yapay sinir ağları oluşturulur (Yurtoğlu, 2005).


Yapay sinir hücreleri mühendislik alanında süreç elemanları olarak da adlandırılmaktadır. Şekil 5.2’de gösterildiği gibi her yapay sinir hücresinin 5 temel elemanı vardır. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılardır (Öztemel, 2012).



Şekil 5.2. Yapay sinir hücresi (Kaynar ve Taştan, 2009)

Yapay sinir ağı, yapay sinir hücrelerinin bir araya gelmesiyle oluşurlar. Genel olarak hücreler üç katman halinde ve her katman içinde paralel olarak bir araya gelmek suretiyle yapay sinir ağını oluştururlar. Bu katmanlar;

- Girdi Katmanı: Bu katmandaki süreç elemanları dış dünyadan gelen bilgileri ara katmanlara transfer ederler.
- Ara Katmanlar: Yapay sinir ağında bir veya birden fazla bulunabilen ara katmanlar girdi katmanının aldığı bilgileri işleyerek çıktı katmanına iletirler.
- Çıktı katmanı: Ara katmandan gelen bilgilerinin işlenerek çıktı üreten ve ürettiği çıktıyı dış dünyaya gönderen katmandır (Öztemel, 2012).



Şekil 5.3 Yapay sinir ağı katmanlarının birbirleri ile ilişkisi

5.3 Yapay Sinir Ağlarında Sınıflandırma

Yapay sinir ağları, yapay sinir hücrelerinin birbirlerine çeşitli şekillerde bağlanmalarından oluşur. Hücrelerin bağlantı şekillerine, öğrenme kurallarına ve transfer fonksiyonlarına göre göre birçok yapay sinir ağ yapısı geliştirilmiştir. Yapay sinir ağları, mimari yapılarına ve öğrenme kurallarına göre sınıflandırılmışlardır (Arıkan Kargı, 2015).

5.3.1 Mimari yapılarına göre yapay sinir ağları

5.3.1.1 İleri beslemeli ağlar (feedforward networks)

İleri beslemeli yapay sinir ağları katmanlar şeklinde düzenlenir. Bu ağlarda nöronlar arasındaki iletişim, giriş katmanından çıktı katmanına doğru tek yönlü bağlantılarla iletilir. Aynı katman içinde yer alan nöronların birbirleriyle bağlantısı yoktur.

İleri beslemeli yapay sinir ağları, öğrenme algoritması olarak geri yayılım öğrenme algoritmasını kullanır. Sinyal işleme, sınıflandırma, şekil tanıma gibi problemlerde genellikle bu ağ yapısı tercih edilir (Arıkan Kargı, 2015).

5.3.1.2 Geri beslemeli ağlar (recurrent networks)

Geri beslemeli yapay sinir ağlarında, çıktı veya katmanlardaki nöronlar çıktılarını tekrardan girdi olarak iletirler. Yani giriş ve çıkış katmanları arasında, ileri beslemeli yapay sinir ağlarının aksine bir döngü söz konusudur. Geri beslemeli ağlar genellikle danışmansız öğrenme kurallarının uygulandığı ağlarda kullanılırlar (Elmas, 2004).

5.3.2 Öğrenme yapılarına göre yapay sinir ağları

Yapay sinir ağlarını sınıflandırılmada kullanılan yöntemlerden birisi de öğrenme yapılarına göre sınıflandırma yapılmasıdır. Danışmanlı öğrenme, danışmansız öğrenme ve takviyeli öğrenme olarak üç tür öğrenme paradigması tanımlanabilir.

Danışmanlı öğrenmeyi, ebeveynlerden yeni bir iş öğrenmeye benzetmek mümkündür. Her denemenin ardından gözlemci tarafından geri bildirimler yapılarak yapılan işin iyileştirilmesine çabalanır. Danışmansız öğrenme, bir yığın dokümanın verilmesi ve bu yığınlar arasından bir şema çıkarılması isteğine dayandırılabilir. Takviyeli öğrenmede ise yapay sinir ağının sisteme sunulan verileri kullanarak tercih yapması (çıktılar üretmesi) gerekir ve doğru yapılan tercihlerin karşılığında ödül vardır. Başarılı ve başarısız tercihlerde geri bildirim yapılır. Tercihin başarılı veya doğru olup olmadığının kararı kullanıcı tarafından belirlenir (Donel, 2012).

5.3.2.1 Danışmanlı (denetimli) öğrenme (supervised learnig)

Danışmanlı öğrenme metoduyla çalışan yapay sinir ağlarında, ağa veri olarak girdi ve çıktı değerleri verilir ve sistemden verilen girdi değerine ait çıktıyı tahmin etmesi istenir. Gerçek çıktı ve yapay sinir ağının tahmini kıyaslanarak, gerçek çıktı ve ağın tahmini arasındaki fark en aza indirilmeye çalışılır. Öğrenme yöntemi, bütün işleme elemanlarının hatalarını en aza indirmeye çalışır. Bu hata azaltma işlemi kabul edilebilir doğruluğa ulaşana dek ağırlıkların değiştirilmesi işlemi devam eder.

Danışmanlı öğrenmede yapay sinir ağı, kullanılmadan önce eğitilmelidir. Gerçek ve sayısallaştırılmış verilerle eğitilen ağ kullanılmaya başlandığında artık yapay sinir hücreleri arasındaki ağırlıklar sabit bir değer olarak belirlenmiş olur. Bazı ağ yapılarında çok düşük oranda da olsa ağ çalışırken eğitime izin verilir (Elmas, 2011).

Danışmanlı öğrenme algoritmalarına örnek olarak, delta kuralı (Widrow and Hoff, 1960), genelleştirilmiş delta kuralı veya geri yayılım algoritması (Rumelhart ve McClelland, 1986) ve LVQ algoritması (Kohonen, 1989) gösterilebilir. Standart otomatik ilişkisel Hopfield ağına öğrenme, danışmanlı öğrenmenin özel bir durumu olarak kabul edilebilir. Ağ, "öğrenme" esnasında özel bir-adımlı prosedürünü ve hatırlama sırasında tekrarlayıcı bir süreç uygular. Bu ağın aksine, diğer çoğu ağ öğrenme aşamasında geri beslemeli bir süreç kullanmaktadır (Pham ve Karaboğa, 2000).

5.3.2.2 Danışmansız (denetimsiz) öğrenme (unsupervised learning)

Danışmansız öğrenmede yapay sinir ağına sadece girdiler verilir. Ağ, girişte verilen örnek değerlere bakarak parametreler arasındaki ilişkileri kendi kendine öğrenir. Bu öğrenme algoritmalarında, istenilen çıktı değerinin bilinmesine gerek yoktur. Danışmansız öğrenme algoritmaları genellikle sınıflandırma problemlerinin çözümünde kullanılır (Arıkan Kargı, 2015).

5.3.2.3 Takviyeli (pekiştirerek) öğrenme (reinforcement learnig)

Bu öğrenme kuralı danışmanlı öğrenmeye yakın bir öğrenme kuralıdır. Takviyeli öğrenmede, danışmanlı öğrenmede olduğu gibi bir eğitici yardımcı olur fakat farklı olarak ağa veri olarak gerçekleşen çıktı değerleri verilmez, sadece girdi değerleri verilir. Ağın oluşturduğu çıktıların ne derece doğru olduğu ağa eğitici tarafından bir sinyal, skor ve ya derece ile geri bildirilir. Ağ eğiticiden aldığı sinyale göre bağlantılarının ağırlıklarını değiştirerek, öğrenme sürecini devam ettirir ve en iyi sonucu bulmaya çalışır (Arıkan Kargı, 2015).

Yapay sinir ağı seçiminden sonra modelin performansını etkileyen en önemli unsur öğrenme algoritmasıdır. Yapay sinir ağı geliştirilmesinde kullanılabilecek çok sayıda öğrenme algoritması olmakla birlikte bu algoritmalarından bazılarının, bazı tip uygulamalar için daha uygun olduğu bilinmektedir. Bu algoritmaların uygulama alanlarına göre sınıflandırılması Çizelge 5.1'deki gibidir (Saraç, 2004).

Çizelge 5.1 Öğrenme algoritmaları ve uygulandıkları alanlar

Uygulama Tipi	Yapay Sinir Ağı
Öngörü Tanıma	Geri yayılım
	Delta Bar Delta
	Geliştirilmiş Delta Bar Delta
	Yönlendirilmiş Rassal Tarama
	Geri Yayılım içinde Self Organizing Map
Sınıflandırma	LVQ (Learning Vector Quantization)
	Olasılıklı Yapay Sinir Ağları

Çizelge 5.1 Öğrenme algoritmaları ve uygulandıkları alanlar (devam)

Uygulama Tipi	Yapay Sinir Ağı
Veri İlişkilendirme	Hopfield
	Boltzmann Makinesi
Kümeleme	ART
	SOM (Self Organizing Map)

Kullanım amaçlarına göre yapay sinir ağı türlerini sınıflandıran bir tabloya Çizelge 5.2’de yer verilmiştir (Arıkan Kargı, 2015).

Çizelge 5.2 Kullanım amaçlarına göre YSA topolojileri

Kullanım Amacı	Ağ Türü	Ağ Kullanımı
Tahmin - Öngörü	Çok Katmanlı Algılayıcı (MLP)	Ağın girdilerinden bir çıktı değerinin tahmin edilmesi
	Radyal Tabanlı Fonksiyon (RBF)	
	Elman Ağı	
	Jordan Ağı	
Fonksiyon Yaklaşırma	MLP	Eldeki birçok veri çiftini işleyerek bunların oluşturduğu bilinmeyen fonksiyonu tahmin etmeye çalışması
	RBF	
Desen (Örüntü) Sınıflandırma	LVQ	Girdilerin hangi sınıfa ait olduğunun belirlenmesi
	ART	
	Olasılık Tabanlı Sinir Ağları	
	Tek veya Çok Katmanlı Algılayıcı	
	RBF	
	Boltzman Makinesi	
Veri İlişkilendirme	Kohonen’s SOM	Girdilerin içindeki hatalı bilgilerin bulunması ve eksik bilgilerin tamamlanması
	Hopfield ağları	
	Boltzman Makinesi	
	ART	
Kümeleme	LVQ	Ağa sunulan bilgileri sınıflandırır
	SOM	
	ART	
Veri Filtreleme	Yeniden Dolaşım (Recirculation)	Girdilerin içindeki hatalı bilgilerin bulunması ve eksik bilgilerin tamamlanması
Optimizasyon	MLP	Belirli kısıtlar altında bir fonksiyonun maksimum veya minimum noktalarının bulunması veya optimum çözümlerin bulunması
	Olasılık Tabanlı Sinir Ağları	
	RBF	

5.4 Yapay Sinir Ağlarının Avantajları ve Dezavantajları

5.4.1 Yapay sinir ağlarının avantajları

Doğrusal Olmama: Yapay Sinir Ağlarını geleneksel yöntemlerden ayıran ve en önemli özelliklerinden birisi; doğrusal problemlerin yanı sıra, doğrusal olmayan, matematiksel olarak modellenmesi güç veya imkânsız olan karmaşık problemlere de çözüm getiriyor olmasıdır.

Öğrenme ve Genelleme: İlham kaynağı insan beyninin çalışma sistemi olan YSA'lar eğitime veya başlangıç tecrübesi sayesinde sisteme sunulan verileri kullanarak öğrenme yeteneğine sahiptir. YSA'lar öğrenme yeteneği sayesinde sisteme sunulan verileri kullanarak genelleme yapabilmektedirler (Özdemir ve Bahadır, 2016).

Bunun yanı sıra YSA'lar yeni bilgilerin ortaya çıkması durumunda yeniden eğitilebilir sistemlerdir. YSA'lar öğrenebilen, eğitilebilen ve genelleme yapılabilen bir sistem olması nedeniyle daha önceden hiç karşılaşmadıkları problemlerin çözülmesinde kullanılabilirler.

Esneklik ve Hata Toleransı: Geleneksel işlemciler tek bir merkezi işlem elemanı ile her hareketi sırasıyla gerçekleştirirken, yapay sinir ağı modelleri her biri büyük bir problemin parçası ile ilgilenen çok sayıda basit işlem elemanından oluşmaktadır (Özdemir ve Bahadır, 2016).

Bu sebepten dolayı geleneksel bilgisayar sistemleri, sistemde oluşabilecek hatalara karşı oldukça duyarlı iken, yapay sinir ağlarında birkaç yapay sinir hücresinin hasarlanması yapay sinir ağının doğru bilgi üretmesini geleneksel yöntemlerde olduğu kadar etkilemez. Geleneksel yöntemlere göre hataya karşı daha fazla toleranslıdırlar.

5.4.2 Yapay sinir ağlarının dezavantajları

Yapay sinir ağlarında uygun ağ yapısının belirlenmesi ve modelin kurulması için belirli bir kurallar seti yoktur. Deneme yanılma yöntemi kullanılır. Bu nedenle ağın kurulması uzun zaman alabilir. Ağın parametre değerlerinin belirlenmesinde kural olmaması nedeniyle kullanıcının tecrübesi önem kazanır. Eğer problem için uygun bir ağ yapısı belirlenemezse, problemlerin çözülememesi veya kötü sonuçların elde edilmesi durumları ile karşılaşılabilir (Arıkan Kargı, 2015). Yapay sinir ağlarının davranışlarının açıklanamayışı ağa olan güveni azaltmakta ve özellikle insan hayatı ile ilgili problemlerde kullanım alanlarını sınırlandırmaktadır.

Geleneksel yöntemler optimum çözümler üretebilirken, yapay sinir ağları optimum sonuçları garanti etmez. Üretilen sonuçlar, iyi sonuçlardan birisi denilebilir. Bunun yanı sıra ağın oluşturulabilmesi için geniş bir veri tabanına ihtiyaç duyulur, problemi temsil eden örnek veri setinin bulunmasının güç olduğu durumlarda, sağlıklı çözümler üretilmemektedir (Öztemel, 2012).

Yapay sinir ağları sadece sayısal veriler ile çalışırlar. Bu nedenle incelenecek problemin bütün verilerinin numerik gösterime çevrilmesi gerekmektedir. Yapay sinir ağları karmaşık yapıda olduklarından bilgisayar ortamında eğitilebilirler. Aksi halde eğitimleri neredeyse imkânsızdır. Bu nedenle yapay sinir ağları donanım bağımlıdır.

Yapay sinir ağının eğitiminin ne kadar sürede tamamlanması gerektiğini gösteren bir yöntem yoktur. Eğitimde hata toleransının belirli bir değerin altına inmesi eğitimi tamamlanması için yeterli görülmektedir.

6. MATERYAL VE YÖNTEM

Bu çalışmada yapay sinir ağları ile imalat sanayi sektöründe faaliyet gösteren işletmeler için finansal başarısızlık öngörü modeli geliştirilerek söz konu işletmelerin bir yıl sonra oluşacak finansal durumlarının bir yıl öncesinden öngörülmesi amaçlanmıştır. Bu nedenle işletmelerin finansal başarısızlığa düşmeden bir yıl önceki bilanço ve gelir tabloları esas alınmıştır.

6.1 Firma Seçimi

Çalışmada geliştirilen modelde değişken olarak finansal oranlar kullanılmıştır. Bilanço ve gelir tablosundan yüzlerce finansal oran çıkarmak mümkündür. Bu oranlar işletmelerin faaliyet gösterdikleri sektörlerle göre anlamlı farklılıklar içerebilirler. Örneğin, konut üreten bir yap-sat (inşaat) firmasının gelirinin düzensizliği, taşımacılık sektöründe faaliyet gösteren bir firmanın stok tutma ihtiyacı duymaması, e-ticaret siteleri ve toptan ve perakende ticaret sektöründe faaliyet gösteren firmaların göreceli olarak daha az duran varlık yatırımlarına gereksinim duyması, imalat sanayi sektöründe faaliyet gösteren işletmelerin makina teçhizat yatırımı, fabrika binası ihtiyacı gibi duran varlık yatırımlarına ihtiyaç duyması gibi durumlar farklı sektörlerde faaliyet gösteren firmaların finansal rasyolarının farklılaşması gibi bir sonuç doğurmuştur. Bu nedenle çalışmada ele alınan işletmelerin seçiminde, farklı sanayii kollarında faaliyet gösterecekler bile imalat yapan işletmeler seçilmiştir.

50 tanesi finansal açıdan başarılı, 50 tanesi finansal başarısız olmak üzere 100 imalat sanayi firması üzerinden bir veri kümesi oluşturulmuştur. Finansal açıdan başarısız olarak değerlendirilen firmalar, kredilerinde 91 gün ve üzeri gecikmeler yaşanmış ve banka tarafından idari takibe aktarılmış firmalar arasından seçilmiştir.

6.2 Değişken (finansal oran) Seçimi

Finansal analiz bir işletmenin mevcut durumunu gösteren ve ilerleyen süreçte finansal durumunun nasıl şekillenebileceği konusunda fikir sahibi olmak için yapılan bir araştırmadır. Finansal analiz, bilanço ve gelir tablosunda yer alan rakamlar kümesinden, anlamlı ve yorumlanabilir finansal oranlar oluşturmak suretiyle özet bilgiler çıkarma işlemidir (Gürsoy, 2007).

Finansal oranların ilk kullanım amacı gelecekteki kârın tahmin edilmesine yönelik olmakla birlikte, değişen ekonomik gelişmelere paralel olarak araştırmacılar; işletme başarısızlığı tahmini, kredi derecelendirilmesi, riskin değerlendirilmesi ve ekonomik hipotezleri test etmek gibi amaçlar için finansal oranlardan yararlanmıştır (Kiracı, 2000). Her sektörün kendine has özellikleri olması sebebiyle belli bir sektördeki işletmenin başarısını ölçerken yine aynı sektöre ait finansal oranların ortalamalarının kullanılması en doğru sonucu verecektir (Çabuk ve Lazol, 2005).

Finansal oranları dört ana başlık altında sınıflandırmak mümkündür. Çalışmamız içerisinde kullanılan finansal oranlar, sınıflandırıldıkları ana başlıklar gözetilerek aşağıda açıklanmıştır.

6.2.1 Likidite oranları:

Likidite durumunun analizinde kullanılan bu oranlar, dönen varlıklar ile kısa vadeli yabancı kaynaklar arasındaki ilişkilerin analizinde kullanılırlar. Bu oranlar işletmelerin kısa vadeli borçlarını ödeyebilme gücünün ölçülmesinde ve çalışma sermayesinin yeterli olup olmadığının tespit edilmesinde kullanılırlar.

Likidite oranları işletmelerin kısa vadeli borçlarını ödeyebilme gücünü ölçmede kullanılırlar ve işletmelerin aktifinde kayıtlı dönen varlıklarıyla kısa vadeli yükümlülüklerini arasında ilişkileri göstermektedirler. Kısa vadeli borç ödeme gücünü yansıtan bu oranlar likidite açısından sıkışık bir işletme inceleniyorsa, üzerlerinde oldukça dikkatli ve titiz çalışılmalıdır (Bozkurt, 2012).

6.2.1.1 Cari oran

Dönen varlıklar ile kısa vadeli yabancı kaynaklar arasındaki ilişkiyi gösteren bir orandır. İşletmenin kısa vadeli borçlarını ödemekte bir güçlükle karşılaşp karşılaşmayacağı veya işletmenin net çalışma sermayesinin yeterli olup olmadığı konusunda fikir verir.

Cari oran, işletmenin sahip olduğu bir yıl içerisinde paraya dönüşmesi mümkün olan dönen varlıklarının, işletmenin bir yıl içinde ödemekle yükümlü olduğu kısa vadeli yabancı kaynaklarına bölünmesi yoluyla hesaplanır. Cari oranın 2 civarında olması olumlu olarak değerlendirilmekle birlikte, ülkemiz şartlarında 1 in üzerinde olması kabul edilebilir olarak değerlendirilmektedir.

$$\text{Cari Oran} = \text{Dönen Varlıklar} / \text{Kısa Vadeli Yabancı Kaynaklar}$$

6.2.1.2 Likit oran (asit-test oranı):

Stoklar hariç olmak üzere, dönen varlıkların kısa vadeli yabancı kaynaklara oranını göstermektedir. Paraya dönüştürülmesi konusunda diğer dönen varlıklara göre daha uzun süre gerektiren ayrıca yine paraya dönüştürülmesi sırasında kayıpların olması muhtemel stoklar kalemi likit oranın hesaplanmasında göz ardı edilmiştir.

Likidite oranı için genel kabul görmüş değer 1'dir. Bu oranın 1 olması; stoklar hariç olmak üzere diğer dönen varlıklar toplamının, firmanın kısa vadeli yabancı kaynaklarının tamamını diğer bir ifadeyle firmanın bütün kısa vadeli borçlarını ödemeye yeterli olacağı anlamına gelmektedir. Türkiye'de imalat sanayi genelinde ortalama likit oranın %70-%80 dolayında olduğu gözlemlenmektedir. İmalat sanayinde faaliyet gösteren bir firmanın likit oranın %70'den düşük olması, firmanın vadesi gelecek yükümlülüklerini / borçlarını ödemekte zorlanma ihtimalini arttırmaktadır.

$$\text{Likit Oran} = (\text{Dönen Varlıklar} - \text{Stoklar}) / \text{Kısa Vadeli Yabancı Kaynaklar}$$

6.2.2 Mali yapı oranları

Mali yapı oranları, bir işletmenin ne ölçüde borçla finanse edildiğini ve borçlanarak finansman sağlamanın işletmeye ne derece yararlı olduğunu ölçmeye yarayan oranlardır. Bu oranlar, işletmelerin faaliyetlerinde zarar etmeleri, aktiflerinin değerinin düşmesi veya gelecek yıllarda faaliyetlerinden fon yaratamaması durumunda, uzun vadeli yükümlülüklerin yerine getirilip getirilemeyeceği konusunda önemli fikirler verirler (Ceylan, 2001).

Mali yapı oranları; işletmenin kaynak yapısının ve daha çok orta ve uzun vadeli borç ödeme gücünün ölçülmesinde kullanılırlar. İşletmenin öz kaynaklarının yeterli olup olmadığı, kaynak yapısı içinde borç / öz kaynak dengesi ve öz kaynak olarak yaratılan fonların ne tür dönen ya da duran varlıklarda kullanıldığının ölçülmesinde kullanılan oranlardır.

6.2.2.1 Toplam borçlar / aktif toplamı (finansal kaldıraç oranı):

Finansal kaldıraç oranı da denilen bu oran, işletme varlıklarının hangi ölçüde yabancı kaynaklarla finanse edildiğini, işletmenin ne ölçüde borca bağımlı olduğunu gösterir. Varlıkların ne kadarının yabancı kaynaklarla finanse edilmesi gerektiğine dair net bir cevap yoktur. Fakat bu oranın %60'ın üzerinde olması bir erken uyarı sinyali olarak değerlendirilebilir.

Ülkemizde kayıt dışı satışların muhasebeleştirilmesinde “Ortaklara Borçlar” kaleminin yoğun olarak kullanılmasından dolayı, uygulama modelimizde kullanılan Finansal Kaldıraç Oranı hesaplanırken formül aşağıda yer aldığı şekilde değiştirilmiştir.

$$\text{Finansal Kaldıraç Oranı} = (\text{Toplam Borçlar} - \text{Ortaklara Borçlar}) / \text{Toplam Aktifler}$$

6.2.2.2 Kısa vadeli mali borçlar / net satışlar:

Bu oran firmanın bankalar ve finans kuruluşlarından kullanmış olduğu kısa vadeli kredilerinin (vadesi 12 ay ve 12 ayın altında olan krediler ile uzun vadeli kredilerin anaparalarının vadesine 12 ay ve altında kalmış olan taksitleri toplamı) firmanın net satışlarına oranıdır. İşletmelerin borç kalemleri arasında yaptırım gücü en yüksek olan ve ödemelerde yaşanacak aksaklıklarının temerrüt oluşturarak işletmenin moralitesini ve kredibilitesini etkilemesi muhtemel olan banka borçlarının işletmenin bir yıllık gelirlerine oranı olarak modele dahil edilmiştir.

Kısa vadeli mali borçlar / net satışlar

6.2.3 Faaliyet oranları

6.2.3.1 Ticari alacaklar / net satışlar:

Çalışma oranları veya verimlilik oranları olarak da adlandırılan faaliyet oranları işletmelerin sahip oldukları varlıkları ne derece etkin kullandıklarını gösteren oranlardır. Başlıca faaliyet oranları; Alacak Devir Hızı, Stok Devir Hızı, Borç Devir Hızı, Öz Sermaye Devir Hızı, Aktif Devir Hızı vb. olmakla birlikte bu çalışmada rakamsal büyüklükler yerine oransal büyüklüklerin veri olarak kullanılması nedeniyle devir hızları yer verilmemiştir.

Sadece firmanın tahsilat kabiliyetini ölçen bir veri olarak ticari alacaklarının net satışlarına oranı veri olarak kullanılmıştır.

Ticari Alacaklar / Net Satışlar

6.2.4 Kârlılık oranları

İşletmelerin faaliyetleri sonucu elde ettikleri kârın yeterli olup olmadığını ölçen oranlardır. İşletmenin kârlılığının az veya çok olduğu kanısına varmak için kârlılık

oranlarını, aynı sektörde faaliyet gösteren diğer firmaların kârlılık oranları ile karşılaştırmak, sektörel oranları baz almak daha doğru bir yaklaşımdır.

6.2.4.1 Brüt satış kârı oranı (brüt kâr marjı):

Bu oran işletmelerin esas faaliyetlerinden kaynaklanan kârlılık durumunu göstermektedir. Brüt kâr marjının yorumlanması için belirli bir standart yoktur. Tercih edilen durum; firmanın brüt kâr marjının faaliyet gösterdiği sektör ortalamalarının ve rakip işletmelerin brüt kâr marjının altında olmaması, yıllar itibarıyla artış göstermesidir

$$\text{Brüt Kâr Marjı} = \text{Brüt Satış Kârı} / \text{Net Satışlar}$$

6.2.4.2 Net kâr marjı oranı:

Net kâr marjı işletmelerin bütün faaliyetleri ve yatırımları sonucunda elde edilen kârı yani nihai sonucu gösterdiği için çok önemlidir. İşletmenin her 1 TL'lik satıştan elde ettiği kârı gösterir. Net kâr marjı oranı için belli bir standart yoktur, ancak büyük ölçekli işletmelerde bu oranın %4 ila %6 arasında olması beklenmektedir.

$$\text{Net Kâr Marjı} = \text{Dönem Net Kârı} / \text{Net Satışlar}$$

6.2.4.3 Öz kaynak (öz sermaye) kârlılık oranı:

Rantabilite oranı olarak da adlandırılan öz sermaye kârlılık oranı, ortakların işletmeye koydukları sermayeye karşılık yeterli getiri elde edip etmediklerini ölçmek amacıyla kullanılır. Bu nedenle ortakların en çok ilgilendikleri kârlılık oranı, öz sermaye kârlılık oranıdır.

$$\text{Öz kaynak Kârlılık Oranı} = \text{Net Kâr} / \text{Öz kaynaklar}$$

6.2.4.5 Favök (ebitda) marjı:

Faiz, Amortisman, Vergi ve Kıdem Tazminatı Öncesi Kârı bir başka ifadeyle esas faaliyet kârını net satışlara oranlayarak bulunmaktadır. İşletmenin esas faaliyetlerinden gelir yaratma yeteneğini ölçmeyi hedefler. Rasyonun yüksekliği kârlılık açısından olumlu değerlendirilir.

$$FAVÖK (EBİTDA) = (Dönem Net Kârı + Vergi + Finansman Gideri + Amortisman Gideri + Kıdem Tazminatı) / Net Satışlar$$

6.3 Yöntem

Bu çalışmada işletmelerin finansal başarısızlıkların, finansal başarısızlığa düşmeden 1 yıl önce öngörülmesi amaçlanmıştır. Bu nedenle modelde kullanılan finansal rasyolar hesaplanırken işletmelerin 1 yıl önceki finansal tabloları (bilanço ve gelir tablosu) kullanılmıştır.

Öncelikle yapay sinir ağları ile bir model oluşturulmuştur. Yapay sinir ağı modeli geliştirilmesinde MATLAB R2013a programının neural network araçları (neural network toolbox - nntool) kullanılmıştır. Daha sonra SPSS programı yardımıyla geleneksel istatistiksel yöntemlerden lojistik regresyon modeli oluşturularak her iki modelin performansları karşılaştırılmıştır.

6.3.1 Yapay sinir ağı modeli

Öncelikle Excel sayfasında yer alan 50 tanesi finansal açıdan başarısız, 50 tanesi finansal açıdan başarılı olmak üzere 100 firmanın finansal tablolarından hesaplanan 9 adet finansal rasyo verisi ve finansal durumunu gösteren sonuç verisi Matlab programına aktarılmıştır. Finansal açıdan başarılı firmaların sonuç değeri “0”, finansal açıdan başarısız firmaların sonuç değeri “1” olarak atanmıştır. Kopuş noktası olarak 0,50 alınmıştır. YSA’nın sonuç olarak 0,50’nin altında değer ürettiği firmalar finansal açıdan başarılı, 0,50’nin

üzerinde sonuç üretilen firmalar ise yapay sinir ağı tarafından finansal açıdan başarısız bulunan firma olarak değerlendirilmiştir.

Sonraki aşamada elimizdeki 100 adet verinin %50'si deney, %50'si kontrol grubu verisi olarak ikiye bölünmüştür. Deney grubuna dâhil veriler ile en iyi tahmini yapan ağ yapısı bulunmaya çalışılmıştır.

Deney grubu verileri ile oluşturulan yapay sinir ağlarının eğitim, doğrulama ve test verisi yüzdesel dağılımında, %70 (34 adet) eğitim verisi, %15 (8 adet) doğrulama verisi, %15 (8 adet) test verisi olacak şekilde dağılım oranı kullanılmıştır.

Oluşturulan çok katmanlı algılayıcı modelde girdi katmanındaki 9 nöron önceki bölümlerde bahsedilen değişkenleri, çıktı katmanındaki 1 nöron ise firmaların finansal başarı durumunu göstermektedir. Oluşturulan modelde gizli katman sayısı 1 olarak alınmıştır. Modelin gizli katmanında yer alan nöron sayısı belli olmamakla birlikte deneme yanılma yöntemiyle belirlenmiştir.

Gizli katmandaki nöron sayıları için 1 nörondan 15 nörona kadar nöron sayıları denenmiş ve her bir nöron sayısı için en iyi tahmin sonucunu veren üç adet yapay sinir ağı modelinin sonuçları çalışma ekine dâhil edilmiştir.

Çalışmada mimari açıdan çok katmanlı ileri beslemeli yapay sinir ağı modeli, öğrenme tipi olarak ise danışmanlı öğrenme tipine sahip yapay sinir ağı modeli kurgulanmıştır. Eğitim algoritması olarak Levenberg-Marquardt (LM) algoritması tercih edilmiştir.

Performans kriteri olarak en küçük hata kareleri ortalaması (MSE) seçilmiştir ve amaç bu değerın sıfır olmasıdır. Genel anlamda performans olarak en iyi sonuçları üreten modeller, en küçük hata kareleri ortalamasının (MSE) en az olduğu değer ve determinasyon katsayısının (R^2) en büyük olduğu değerlerdir. MSE değeri Matlab programının ürettiği sonuçlar kullanılarak Excel programında hesaplanış, R^2 değerleri için ise eğitim, doğrulama ve test değerlerinin tamamında Matlab plot regresyon ekranı alınmıştır. Oluşturulan yapay

sinir ağı modellerinin hepsi test için ayırdığımız 50 örnek işletme verisi ile test edilmiş, yapılan tüm testlerin tahmin başarı oranları, R^2 değerleri ve MSE değerleri hesaplanarak performans tablosuna dâhil edilmiştir. Bu bağlamda performans olarak en başarılı model en iyi tahmin sonucunu üreten model olarak seçilmiştir. Bu model aynı zamanda performans kriteri olarak belirlediğimiz en küçük hata kareleri ortalamasının (MSE) değerinin en küçük olduğu değerdir.

6.3.2 Lojistik regresyon modeli

Oluşturulan yapay sinir ağı modelinin geçerliliğinin teyit edilmesi ve başka bir modelle karşılaştırılması amacıyla, yapay sinir ağı eğitiminde kullanılan deney grubu verileri ve ağı test edilmesinde kullanılan test grubu verilerinin tamamıyla lojistik regresyon modeli oluşturularak iki farklı yöntemle elde edilen sonuçlar karşılaştırılmıştır.

Çok değişkenli istatistiksel yöntemlerden biri olan lojistik regresyon analizi, bağımlı değişkenin kategorik olarak ikili, üçlü ve ya çoklu kategorilerde gözlemlendiği durumlarda ve bağımlı değişkenin bağımsız değişkenlerle sebep-sonuç ilişkisini belirlemede yararlanılan bir yöntemdir. Bağımsız değişkenlere göre bağımlı değişkenin beklenen değerinin, olasılık olarak elde edildiği yöntem, sınıflama işlemleri yapmaya yardımcı olur. Lojistik regresyon analizi aşağıda belirtilen amaçlara yönelik uygulanabilir (Özdamar, 2004):

- Kategorik veya sürekli bağımsız değişkenlere dayanarak bağımlı değişkenin tahmin edilmesi,
- Bağımlı değişkendeki varyansın bağımsız değişkenler tarafından açıklanan yüzdesinin belirlenmesi,
- Etkileşim terimlerinin değerlendirilmesi.

Lojistik regresyon analizi, bağımlı değişkeni nitel (kategorik) olan modelleri oluşturmada başarılı ve esnek bir istatistiksel analiz yöntemidir. Bu yöntemde bağımsız değişkenler kesikli, sürekli veya kategorik değişken olabilirler. Benzer istatistiksel yöntemlere kıyasla çok daha az varsayım gerektirmesinden dolayı rahatlıkla esnek olarak sınıflandırılacak bir yöntemdir (Yakıcı Ayan ve Değirmenci, 2018).

Lojistik regresyon modeli hakkında fikir verebilecek özet bilgiler paylaşılmış olup bundan sonraki aşamada oluşturulan lojistik regresyon modeli ve sonuçları hakkında bilgilendirme yapılacaktır. Çalışmamızda oluşturulan firmaların finansal başarı durumlarına göre sınıflandırılması amacıyla oluşturulan lojistik regresyon modelimizde 9 adet bağımsız değişken olup bu değişkenler çalışmamızın 6. bölümünde yer alan değişkenlerdir. Bağımlı değişken olarak ise firmanın finansal başarı durumu alınmış ve “finansal başarı durumu” adıyla modelimize kategorik bağımlı değişken olarak dâhil edilmiştir. Bağımlı değişkenimiz olan finansal başarılı durumu, finansal başarılı firmalar için “0”, finansal başarısız firmalar için “1” olarak tanımlanmıştır. Çizelge 6.1’de modelimizde yer alan bağımsız değişkenler ve kodlarına, Çizelge 6.2’de ise omnibus testi sonuçlarına yer verilmiştir.

Çizelge 6.1 Lojistik regresyon modelinde yer alan bağımsız değişkenler tablosu

Bağımsız Değişken Kodu	Bağımsız Değişken Adı
X1	Cari Oran
X2	Likit Oran
X3	Toplam borçlar/aktif toplamı
X4	Ticari alacaklar / net satışlar
X5	Brüt Kâr Marjı
X6	Net Kâr Marjı
X7	Öz kaynak Kârlılık Oranı
X8	Ebitda
X9	Kısa vadeli mali borçlar / net satışlar

Çizelge 6.2 Lojistik regresyon modeli omnibus testi sonuçları

		Chi-square (Ki-Kare)	df (Serbestlik Derecesi)	Sig. (Anlamlılık)
Adım 1	Adımsal	124,053	9	,000
	Blok	124,053	9	,000
	Model	124,053	9	,000

Çizelge 6.3’de lojistik regresyon modeline ilişkin log-olabilirlik değeri ve determinasyon katsayıları (Cox&Snell R^2 , Nagelkerke R^2) görülmekte olup, finansal başarı

durumunun bağımsız değişkenler tarafından iyi düzeyde açıklanabildiği sonucuna varılabilir.

Çizelge 6.3 Lojistik regresyon model özeti

Adım	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	14,577 ^a	,711	,948

Çizelge 6.4 Lojistik regresyon modeli değişkenleri

Bağımsız Değişkenler	B (Katsayı)	S.E. (Standart Hata)	Wald (Wald İstatistiği)	df (Serbestlik Derecesi)	Sig. (Anlamlılık)
Adım 1					
X1	7,919	4,569	3,004	1	,083
X2	-29,228	16,158	3,272	1	,070
X3	40,180	24,536	2,682	1	,102
X4	23,291	13,889	2,812	1	,094
X5	-17,715	16,051	1,218	1	,270
X6	-172,598	93,341	3,419	1	,064
X7	2,491	6,925	,129	1	,719
X8	-1,091	,563	3,756	1	,053
X9	-9,088	7,216	1,586	1	,208
Sabit	-10,634	11,786	,814	1	,367


Çizelge 6.4’de sonuçları verilen %10 anlamlılık düzeyinde Wald Testi sonuçlarına X1 (Cari oran), X2 (Likit oran), X4 (Ticari alacaklar / Net satışlar), X6 (Net Kâr Marjı) ve X8 (Ebitda) değişkenleri anlamlıdır. Modelin sınıflandırma sonuçlarına ilişkin bilgilere bir sonraki bölümde yer verilmiştir.

7. BULGULAR VE TARTIŞMA

Bu çalışmada tek gizli katmanlı MLP (çok katmanlı algılayıcı) modeli, yapay sinir ağı mimarisi olarak ileri beslemeli sinir ağı modeli, öğrenme tipi olarak ise danışmanlı öğrenme tipini içeren yapay sinir ağı modelleri oluşturulmuştur. En iyi tahmin sonuçlarını üreten modelin araştırılması aşamasında, deney grubu verileri ile yapay sinir ağlarının eğitimi için hatayı geriye doğru yayan algoritmalarından Levenberg-Marquart (LM) algoritması tercih edilmiştir. Gizli katmandaki nöron sayısının tespit edilmesi konusunda deneme yanılma yöntemi kullanılmış ve en iyi sonuçları üreten modellerin sonuçlarına Çizelge 7.1’de yer verilmiştir. Her bir nöron sayısı ile onlarca yapay sinir ağı modeli oluşturulmuş, her nöron sayısına ait en iyi 3 sonucu veren modeller Çizelge 7.1’e aktarılmıştır.

Matlab programında YSA eğitimi yapılırken maksimum iterasyon (epoch) sayısı 1000, maksimum doğrulama kontrolü sayısı 6 olarak seçilmiştir. Oluşturulan ağların performans kriteri en küçük hata kareleri ortalaması (MSE) olarak seçilmiştir ve hedef MSE değerinin sıfır olmasıdır.

Yukarıda bahsedilen parametreler doğrultusunda oluşturulan modeller arasında en iyi sonucu veren model gizli katmanında 5 nöron yer alan 9-5-1 ağ yapılı MLP modeli olarak belirlenmiştir. 9-5-1 ağ yapılı MLP modelinin ağ görünümü Şekil 7.1’de verilmiştir. En başarılı öngöründe bulunan 9-5-1 ağ yapılı model ve oluşturulan diğer modellerin tahmin güçleri Çizelge 7.1’e aktarılmıştır.



Şekil 7.1 En iyi sonucu veren 9-5-1 MLP ağ yapılı, YSA model görünümü

Çizelge 7.1 En uygun YSA modelini belirlemek için yapılan denemeler

Deneme Sayısı	Nöron Sayısı / Deneme Sayısı	R	R ²	MSE	Doğru Tahmin Sayısı	Hatalı Tahmin Sayısı	Başarı Yüzdesi
1	1 / 1	0,94396	0,89106	0,15572701	43	7	86%
2	1 / 2	0,92439	0,854497	0,10006585	43	7	86%
3	1 / 3	0,95753	0,916864	0,10006585	43	7	86%
4	2 / 1	0,92039	0,847118	0,06569058	44	6	88%
5	2 / 2	0,97447	0,949592	0,11095872	43	7	86%
6	2 / 3	0,93592	0,875946	0,08678476	45	5	90%
6	3 / 1	0,98662	0,973419	0,15105905	42	8	84%
7	3 / 2	0,98662	0,973419	0,10244443	43	7	86%
8	3 / 3	0,92587	0,857235	0,17151304	41	9	82%
9	4 / 1	0,96077	0,923079	0,12009297	44	6	88%
10	4 / 2	0,9449	0,892836	0,07481571	45	5	90%
11	4 / 3	0,92562	0,856772	0,10838443	42	8	84%
12	5 / 1	0,96075	0,923041	0,06295599	47	3	94%
13	5 / 2	0,91351	0,834501	0,11516943	43	7	86%
14	5 / 3	0,96076	0,92306	0,15173992	42	8	84%
15	6 / 1	0,94371	0,890589	0,09708554	43	7	86%
16	6 / 2	0,93776	0,879394	0,12785836	41	9	82%
17	6 / 3	0,92997	0,864844	0,12006192	44	6	88%
18	7 / 1	0,94491	0,892855	0,0832306	45	5	90%
19	7 / 2	0,8954	0,801741	0,11606944	44	6	88%
20	7 / 3	0,95773	0,917247	0,11018764	43	7	86%
21	8 / 1	0,93342	0,871273	0,0990777	42	8	84%
22	8 / 2	0,90872	0,825772	0,10819019	44	6	88%
23	8 / 3	0,93342	0,871273	0,1253991	42	8	84%
25	9 / 1	0,94899	0,900582	0,12001003	45	5	90%
26	9 / 2	0,96255	0,926503	0,0740289	45	5	90%
27	9 / 3	0,93449	0,873272	0,08639052	44	6	88%
28	10 / 1	0,91242	0,83251	0,10100015	42	8	84%
29	10 / 2	0,90847	0,825318	0,10143671	42	8	84%
30	10 / 3	0,93808	0,879994	0,16639432	41	9	82%
31	11 / 1	0,9112	0,830285	0,10054675	42	8	84%
32	11 / 2	0,92912	0,863264	0,1165933	43	7	86%
33	11 / 3	0,98209	0,964501	0,12917974	43	7	86%
34	12 / 1	0,93405	0,872449	0,12749592	42	8	84%
35	12 / 2	0,97819	0,956856	0,18208906	39	11	78%
36	12 / 3	0,91338	0,834263	0,12761487	42	8	84%

Çizelge 7.1 En uygun YSA modelini belirlemek için yapılan denemeler (devam)

Deneme Sayısı	Nöron Sayısı / Deneme Sayısı	R	R ²	MSE	Doğru Tahmin Sayısı	Hatalı Tahmin Sayısı	Başarı Yüzdesi
37	13 / 1	0,96101	0,92354	0,12867679	41	9	82%
38	13 / 2	0,96101	0,92354	0,08971111	44	6	88%
39	13 / 3	0,93846	0,880707	0,09318198	43	7	86%
40	14 / 1	0,96072	0,922983	0,11427185	44	6	88%
41	14 / 2	0,88319	0,780025	0,12231712	44	6	88%
42	14 / 3	0,92085	0,847965	0,08307556	44	6	88%
43	15 / 1	0,91637	0,839734	0,21819356	39	11	78%
44	15 / 2	0,91637	0,839734	0,14544287	41	9	82%
45	15 / 3	0,96076	0,92306	0,13424229	43	7	86%

9-5-1 ağ yapılı yapay sinir ağı modelinde; giriş nöronları (9 adet) ve gizli katman nöronları (5 adet) arasındaki ağırlık değerleri Çizelge 7.2’de, gizli katmandaki nöronların eşik değerleri Çizelge 7.3’de, gizli katmandaki nöronlar ile çıkış katmanındaki nöron arasındaki ağırlık değerleri Çizelge 7.4’de, çıktı katmanındaki nöronun eşik değeri Çizelge 7.5’de verilmiştir.

Çizelge 7.2 Giriş nöronları ile gizli katman nöronları arasındaki ağırlık değerleri

	1	2	3	4	5
1	-0,86178	0,76615	-1,1096	0,53915	2,3121
2	-0,4092	0,48784	0,784845	-1,2084	-4,5357
3	-0,56658	1,9131	0,79073	-1,1111	4,889
4	-0,77333	-1,021	0,79687	-1,8734	1,3748
5	-0,69486	-2,0007	-2,3128	-1,1929	0,44606
6	0,65916	-2,2086	0,8484	-1,867	-5,8889
7	0,04993	-0,23041	0,35677	-0,63209	0,96358
8	0,50312	0,37087	2,6656	-0,435212	-4,2408
9	-0,014265	1,8494	-0,75615	1,6589	-0,25153

Çizelge 7.3 Gizli katmandaki nöronların eşik değerleri

Gizli Katmandaki Nöronlar	Eşik Değerleri
1	4,3942
2	5,4446
3	-2,503
4	2,1491
5	8,0849


Çizelge 7.4 Gizli katmandaki nöronlar ile çıkış katmanındaki nöron arasındaki ağırlık değerleri

	1	2	3	4	5
1	1,946	-0,26775	0,67446	-0.38899	0,15806

Çizelge 7.5 Çıktı katmanındaki nöronun eşik değeri

Çıkış katmanındaki nöron	Eşik değeri
1	3,5942

Gizli katmanında 5 nöron yer alan, MSE değeri 0,06295599 olarak gerçekleşen ve test grubu ile tahmin yapıldığında %94 oranında başarılı tahmin yapan 9-5-1 ağ yapılı çok katmanlı yapay sinir ağı modelimizin, deney grubu verileri ile eğitim sırasında gerçekleşen R değerleri ve Matlab programından alınan plot regresyon ekranı Şekil 7.1’de bilginize sunulmuştur.



Şekil 7.2 Deney grubu plot regresyon sonuçları

Çizelge 7.1’de oluşturulan 45 adet yapay sinir ağı modelinin finansal başarı durumunu öngörü sonuçlarına yer verilmişti. Bu defa en iyi sonucu veren 9-5-1 ağ yapılı çok katmanlı yapay sinir ağı modelimizin öngörü sonuçları hakkında daha detaylı bilgiler Çizelge 7.6’da aktarılmıştır.

Çizelge 7.6 Yapay sinir ağı modeli sınıflandırma tablosu

		Tahmin		
		Finansal Başarı Durumu		Tahmin Başarı Yüzdesi
		Finansal Başarılı	Finansal Başarısız	
Finansal Başarı Durumu	Finansal Başarılı	23	2	% 92,0
	Finansal Başarısız	1	24	% 96,0
Toplam Başarı Yüzdesi				% 94,0

Yapay sinir ağı modelinin firmaları finansal durumlarına göre sınıflandırma başarıları %94’dir. Test grubuna ait 50 firmadan, 47 tanesi doğru, 3 tanesi ise yanlış sınıflandırılmıştır. 25 tane finansal başarılı firmanın, 23 tanesi finansal başarılı, 2 tanesi ise finansal başarısız olarak sınıflandırılmıştır. Bunun yanında gerçekte finansal açıdan başarısız olan 25 tane firmadan, 1 tanesi finansal açıdan başarılı, 24 tanesi ise doğru bir şekilde finansal açıdan başarısız olarak sınıflandırılmıştır.

Yapay sinir ağı modelimizin sonuçlarını kıyaslamak için oluşturulan lojistik regresyon modelinin işletmeleri finansal başarı durumlarına göre sınıflandırma sonuçları Çizelge 7.7’de verilmiştir.

Çizelge 7.7 Lojistik regresyon analizi sınıflandırma tablosu

			Tahmin		
			Finansal Başarı Durumu		Tahmin Başarı Yüzdesi
			Finansal Başarılı	Finansal Başarısız	
Adım 1	Finansal Başarı Durumu	Finansal Başarılı	47	3	% 94,0
		Finansal Başarısız	2	48	% 96,0
	Toplam Başarı Yüzdesi				% 95,0

Lojistik regresyon modelinin firmaları finansal durumlarına göre sınıflandırma başarısı %95'dir. 100 firmasın 95 tanesi doğru, 5 tanesi ise yanlış sınıflandırılmıştır. 50 tane finansal başarılı firmanın, 47 tanesi başarılı, 3 tanesi ise finansal başarısız olarak sınıflandırılmıştır. Bunun yanında gerçekte finansal açıdan başarısız olan 50 tane firmadan, 2 tanesi finansal açıdan başarılı, 48 tanesi ise doğru bir şekilde finansal açıdan başarısız olarak sınıflandırılmıştır.

Kıyaslamalar sonucunda iki yöntemin, performanslarının finansal başarılı ve finansal başarısız firmaların doğru sınıflandırılmasında birbirine çok yakın sonuçlar ürettiği gözlemlenmiştir.

8. SONUÇ VE ÖNERİLER

Varsayım olarak faaliyetlerini sonsuza kadar sürdüreceği kabul edilen işletmelerin bir kısmı, gerek işletmeye bağlı nedenler, gerekse genel ekonomik aktivite ve makroekonomik nedenlerle finansal başarısızlık riski ile karşı karşıya kalmaktadır.

Finansal başarısızlık tahmini özellikle bankaların alacakları riskin öngörülmesi ve kredilendirme sürecinde bu öngörüler doğrultusunda kredi tespiti ve teminatlandırma konusunda kredi tahsis uzmanlarına yön göstermesi bakımından gün geçtikçe daha fazla önem arz eden bir konudur. Günümüzde bankaların kredi başvurusu yapan firmalar hakkında düzenlenen kredi skorlarında firmanın finansal bilgilerinin yanı sıra, işletmenin önümüzdeki bir yıl içerisinde temerrüde düşme riskini içeren bir puanlama yaptıkları bilinmektedir.

Bankalar kredi tahsis aşamalarında temerrüt / iflas riskini yüksek oranda başarılı bir şekilde öngören modeller ve skorlama teknikleri kullanarak kaynaklarını daha az risk taşıyan firmalarda kullanabilir, mevcutta çalışılan firmalarla ilgili olarak ise periyodik firma değerlendirmesi esnasında temerrüt / iflas riski yükselen firmalarda bir erken uyarı sinyali olarak kullanarak, daha hızlı aksiyon alabilir ve kredi riskini minimize edebilirler.

Finansal açıdan başarılı firmaların başarısız olarak sınıflandırılması ile finansal açıdan başarısız firmaların başarılı olarak sınıflandırılması durumlarının her ikisi de hatalı bir tahmin olsa da maliyetleri farklıdır. Başarılı bir firmayı başarısız olarak sınıflandırmak ve bu kararın kreditorlerce uygulanması bir potansiyel müşteri ve kâr kaybını ifade etmektedir. Fakat finansal başarısız bir firmanın başarılı olarak sınıflandırılması ve bu kararın kreditorlerce göz önünde bulundurularak kredi tahsisi yapılması, bankaların mevcut kaynaklarını tahsil etme imkânı çok zor olan firmalara aktarması sonucunu doğurur. Buna bağlı olarak kaynak kaybının yanı sıra söz konusu müşteriler için kredi riskinin %100'ne varan oranlarda özel karşılık ayrılması, kredi riski kadar kaynağın kullanılamaması anlamını taşır. Ayrıca risk tahsil ve tasfiyesi için harcanan emek, operasyonel masraflar ve banka bilançosuna kötü etkisini değerlendirecek olursak çok ciddi bir maliyet oluşturacaktır.

Bu çalışmada oluşturulan yapay sinir ağı modeli, 25'i finansal başarısız, 25'i finansal açıdan başarılı 50 firma verisi test edilmiştir. Modelimizi finansal başarılı firmaları %92, finansal başarısız firmaları %96 oranında, toplamda ise %94 oranında doğru sınıflandırmıştır. Bu oran literatürde yapılan diğer çalışmalar ve başarı oranlarına bakıldığında makul bir oran olarak değerlendirilmiştir. Bunun yanı sıra yapay sinir ağı modelimizin sonuçları değerlendirilirken 0,5 kopuş noktası olarak alınmış, 0,5'ten küçük çıktı değeri tahmin edilen firmalar finansal başarılı, 0,5'ten büyük çıktı değeri tahmin edilen firmalar finansal başarısız olarak değerlendirilmiştir. Görüldüğü üzere modelin çıktı değeri büyüdükçe finansal başarısız olma riski artmaktadır. Bu bağlamda yapay sinir ağı modelinin ürettiği çıktı değerlerine, temerrüt olasılığı riski olarak, kredi talep eden firmalar hakkında düzenlenen mali tahlil raporları, skorkartlar ve firma kredi derecelendirme vb. raporlarında yer verilebileceği düşünülmektedir.

Modelimizin kıyaslanması için lojistik regresyon modelinin ise benzer sonuçlara üreterek finansal başarılı firmaları %94, finansal başarısız firmaları %96 oranında, toplamda ise %95 oranında doğru sınıflandırdığı görülmüştür.

Çalışmada oluşturulan yapay sinir ağı modeli statik bir model olup, eğitimin sonlandırılması ile birlikte nöronlar ve katmanlar arasındaki ağırlık değerleri sabitlenmiştir. Oluşturulan yapay sinir ağı öğrenmeyi durdurmuştur ve mevcut yapısı ile farklı firmalarla test edilse dahi ağı içerisinde yer alan ağırlık değerleri değişmeyecektir. Bankacılık gibi dinamik ve sürekli olarak milyonlarca veri ile beslenen bir sektörde dinamik yapıya sahip yapay sinir ağı modelleri oluşturularak yapay sinir ağı modelinin eğitiminin sürekli olması sağlanabileceği ve daha başarılı sonuçlar elde edilebileceği düşünülmektedir.

Bununla birlikte yapay sinir ağlarının bankacılık ve finans alanında mobil bankacılık ve internet bankacılığı gibi alanlarda kullanılabileceği gibi pazarlama alanında müşteri bilgilerinin aktarılacak müşteri ihtiyacının banka tarafından önceden tespit edilmesine imkân sağlayan ve bu sayede pazarlama faaliyetlerinde ilgili kurumu bir adım öne geçirebilecek yapay zekâ teknikleri ve yapay sinir ağı modellerinin oluşturulması mümkündür.

Kredi deęerlendirme dinamik ve gerek zamanlı özömlenmesi gereken bir problemdir. Yöntemler, veri setinin büyüklüęü, özellięi, vb. niteliklerinden etkilenmektedirler. Tek bir regresyon modelinin böyle bir problemi tatmin edici şekilde özömlenmesi beklenmez. Bu nedenle farklı yöntemlerden elde edilen göstergelerin karar vericilere (kredi tahsis birimlerine) sunulması daha uygundur. Farklı yöntemlerden elde edilen kredi risk parametrelerinin sunulması bu amaca yönelik karar destek sistemlerinin en önemli özelliklerindendir. Akademik olarak her koşulda daha üstün bir öngörü yönteminin varlığı incelenmekte iken yapılacak en doğru hamle birden fazla yöntemin öngörülerini sağlayan ve deęerlendirmeyi kreditörlere bırakan bir karar destek sistemi yaklaşımı olacaktır.

KAYNAKLAR DİZİNİ

- Aktaş R., Doğanay M., Yıldız B., 2003, İstatistiksel Yöntemler ve Yapay Sinir Ağı Karşılaştırması, Ankara Üniversitesi SBF Dergisi, Cilt 58, Sayı 4, s.1-23.
- Aktaş, R., 1993, Endüstri İşletmeleri İçin Finansal Başarısızlık Tahmini, Türkiye İş Bankası Kültür Yayınları, s.7., 16., 81.
- Alfaro E., Garcia N., Gamez M. ve Elizondo D., 2008, Bankruptcy Forecasting: An Ampirical Comparison Of Adaboost And Neural Networks Original Research Article. Decision Support Systems, Volume 45, Issue 1, p.110-122.
- Altman E., 1968, Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy, The Journal of Finance, 23(4), p.589-609.
- Arıkan Kargı, V. S., 2015, Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama, Ekin Basın Yayın Dağıtım, s.31.-32., 65.-67., 72.
- Bakır Yiğitbaş Ş.B., Bankaların Kredi Verme Davranışı Üzerine Asimetrik Bilginin Etkisi ve Reel Sektör Yansıması (Türkiye Analizi 2002-2010), Türkiye Bankalar Birliği, s.18.
- BDDK, 2017, Bankalarca Kredilerin ve Diğer Alacakların Niteliklerinin Belirlenmesi ve Bunlar İçin Ayrılacak Karşılıklara İlişkin Usul Ve Esaslar Hakkında Yönetmelik, https://www.bddk.org.tr/WebSitesi/turkce/Mevzuat/Bankacilik_Kanununa_Iliskin_Duzenlemeler/167171707karsilik_yonetmelik_18_7_2017.pdf, erişim tarihi: 26.05.2018
- Beaver W.H., 1966, Financial Ratios As Predictors of Failure, Journal of Accounting Research, 4, p.70-1122
- Bigus, J. P., 1996, Data Mining with Neural Net Networks, McGraw-Hill, p.24.
- Bozkurt N., Muhasebe Denetimi, Alfa Yayıncılık, s.173.
- Ceylan A., 2001, İşletmelerde Finansal Yönetim, Ekin Kitabevi Yayınları, s.46.
- Çetiner E., 2000, İşletmelerde Mali Analiz, Gazi Kitabevi, s.142.
- Çabuk A., Lazol İ., 2005, Mali Tablolar Analizi, Nobel Yayın Dağıtım, s.185.
- Çabukel R., 2007, Bankaların Kurumsal Kredileri Açısından Kredi Riski Yönetimi ve Basel-II Uygulaması, Türkiye Bankalar Birliği, s.8., 30-31, 41

KAYNAKLAR DİZİNİ (devam)

- Donel B., 2012, Yapay Sinir Ağları Yöntemi İle Kredi Skorlama, Yüksek Lisans Tezi, İ.T.Ü. Fen Bilimleri Enstitüsü İşletme Mühendisliği Ana Bilim Dalı, 106 s. (yayımlanmış)
- Du Juardin P., 2010, Predicting bankruptcy using neural networks and other classification methods: the influence of variable selection techniques on modal accuracy, Neurocomputing Volume 73, Issues 10-12, p.014-2060
- Elmas Ç., 2004, Yapay Zekâ, Popüler Bilim Yayınları, s.63.
- Elmas Ç., 2011, Yapay Zekâ Uygulamaları, Seçkin Yayıncılık, s.88.
- Ercan M.K., Ban Ü., 2012, Finansal Yönetim, Gazi Kitabevi, s.40.
- Gürsoy C.T., 2007, Finansal yönetim ilkeleri, Doğu Üniversitesi Yayınları, s.189.
- İçerli M.Y., Akkaya G.C., 2006, Finansal Açından Başarılı Olan İşletmelerle Başarısız Olan İşletmeler Arasında Finansal Oranlar Yardımıyla Farklılıkların Tespiti, Ankara Üniversitesi İktisadi ve İdari Bilimler Dergisi, s.413.
- JO H., HAN I., 1997, Bankruptcy Prediction Using Case-Based Reasoning, Neural Networks, and Discriminant Analysis, Expert Systems With Applications, 13, p.97-108.
- Kaynar O., Taştan S., 2009, Zaman Serisi Analizinde Yapay Sinir Ağları ve Arıma Modelinin Karşılaştırılması, Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Sayı: 33, s.163
- Keskin Benli Y., 2005, Bankalarda Finansal başarısızlığın Öngörülmesi Lojistik Regresyon ve Yapay Sinir Ağı Karşılaştırması” Gazi Üniversitesi Güzel Sanatlar Eğitim Fakültesi Dergisi, Sayı:16, s.31-46.
- Kiracı, M., 2000, “İşletmelerin Finansal Başarısızlığında Çalışma Sermayesi Yönetiminin Rolünün Oranlar Yardımıyla Tespiti ve Ampirik Bir Araştırma”, Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı, 131 s. (yayımlanmış)
- Kurtaran Ç., 2010, “Bankaların Finansal Başarısızlıklarının Geleneksel ve Yeni Yöntemlerle Öngörüsü”, Yönetim ve Ekonomi Dergisi Celal Bayar Üniversitesi İ.İ.B.F., s.129-143.

KAYNAKLAR DİZİNİ (devam)

- Mirza, A., 2006, Kredi riski yönetiminde erken uyarı sistemleri ve sorunlu kredilerin izlenmesi, Yüksek lisans tezi, Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü, 235 s. (yayımlanmış)
- Nguyen, H. G., 2005, Using Neutral Network in Predicting Corporate Failure, Journal of Social Sciences 1 (4): p.199–202.
- Odom M., Sharda R., 1990, “A Neural Network Model For Bankruptcy Prediction”, IEEE Int. Conf. on Neural Network, Vol.2, p.163-168.
- Özdamar K., 2004, Paket Programlar ile İstatiksel Veri Analizi, Kaan Kitabevi, s.589.
- Özdemir A.E., Bahadır E., 2016, Akademik Başarı Tahmininde Yapay Sinir Ağları, Burç Yayınevi, s.17., 50-52.
- Öztemel E., 2016, Yapay Sinir Ağları, Papatya Yayıncılık Eğitim, s.29.
- Pham D.T., Karaboga, D., 2000, Intelligent Optimisation Techniques: Genetic Algorithms, Tabu Search, Simulated Annealing and Neural Networks, Springer, p.18-25.
- Polat E., 1995, Türk Bankacılık Sisteminde Problemlili Kredileri Önceden Belirleyecek Model Geliştirilmesi İçin Bir Çalışma, Pamukbank T.A.Ş. Eğitim Yayınları, s.2.
- Rudorfer G., 1995, Early Bankruptcy Detection Using Neural Networks, APL Quote Quad 25 4.9 , p.171-176
- Saraç T., 2004, Yapay Sinir Ağları Seminer Projesi, Gazi Üniversitesi Endüstri Mühendisliği Anabilim Dalı, s.35.
- Seval, B., 1990, Kredilendirme Süreci ve Kredi Yönetimi, İstanbul Üniversitesi İşletme Fakültesi Muhasebe Enstitüsü Yayını, s.36–37, 225-228.
- Shin K.S., Lee Y-J., 2002, A genetic algorithm application in bankruptcy prediction modeling original research article. Expert System with Applications, Volume 23, Issue 3, p.321-328.
- Sonbul İskender E., 2014, Kredi Riski Dayanıklılığının Analizi: Türk Bankacılık Sektörü Üzerine Politika Önerileri, Türkiye Bankalar Birliği, s.5-7.
- Tamari M., 1970, The Nature of Trade Credit, Oxford Economic Papers, New Series, Vol.22, Nr.3, p.406-419.

KAYNAKLAR DİZİNİ (devam)

- TBB, 2018, Risk Merkezi Aylık Bülteni Mart 2018, [https://www.riskmerkezi.org/Content/Upload/istatistikraporlar/ekler/1299/Risk Merkezi Aylık Bulteni Mart 2018.pdf](https://www.riskmerkezi.org/Content/Upload/istatistikraporlar/ekler/1299/Risk_Merkezi_Aylık_Bulteni_Mart_2018.pdf), erişim tarihi: 26.05.2018
- Yakıcı Ayan T., Değirmenci N., 2018, Firma Finansal Başarısızlık Öngörüsü İçin Bir Lojistik Regresyon Modeli, Uluslararası İktisadi ve İdari İncelemeler Dergisi, 18. Eyi Özel Sayısı, s.82.
- Yurtoğlu H., 2005, Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi:Bazı Makroekonomik Değişkenler İçin Türkiye Örneği, DPT Uzmanlık Tezleri – Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü Yayınları s.10-26.