

ARAŞTIRMA MAKALESİ

HALKA AÇIK FİNANS DIŞI ŞİRKETLERDE SÜREKLİLİK RİSKİNİN KARAR AĞACI MODELİ İLE ÖNGÖRÜLMESİ*

GOING CONCERN PREDICTION VIA DECISION TREE MODELS AMONG NON-FINANCE PUBLIC COMPANIES

Prof. Dr. Gülümser ÜNKAYA**
Gürkan SAYIN***

ÖZ

Bu çalışmanın amacı bir makine öğrenmesi modeli olan karar ağacının finans dışı şirketlerin süreklilik risklerinin öngörülmesine yapabileceği katkının irdelenmesidir. Çalışma kapsamında yapılan analizlere 1999-2016 döneminde Türkiye’de yerleşik, halka açık, finans sektörü dışındaki şirketler dâhil edilmektedir. Araştırmada R istatistik dilinden ve ilgili R makine öğrenmesi model kütüphanelerinden (rpart ve partykit) faydalanılmaktadır. Modelin etkinlik ölçümleri çapraz doğrulama yöntemi ile gerçekleştirilmektedir. Çalışma sonucunda veriye uygulanan karar ağacı modelinin %91 seviyesinde bir başarı ile süreklilik risklerini öngörebildiği tespit edilmektedir. Model, eldeki örneklem çerçevesinde, yüksek performansının yanında kolay anlaşılır ve uygulanabilir olmasıyla pratikte de faydalı olabileceğine işaret etmektedir. Ortaya çıkan Karar Ağacı modelinin her seviyedeki muhasebe bilgi kullanıcıları (yöneticiler, ortaklar, kredi kuruluşları, çalışanlar, potansiyel ortaklar, devlet ve toplum) tarafından işletilebilmesi ve kredi riski takip uygulamalarına eklenilebilmesi mümkün görünmektedir.

Anahtar Sözcükler: Karar ağacı modeli, süreklilik riski öngörüsü, halka açık finans dışı şirketler, Türkiye.

ABSTRACT

This research aims to determine the potential of decision trees, a subclass of machine learning models, in going concern prediction among non-finance

* Bu makale doktora tezinden çıkarılmıştır. İstanbul Aydın Üniversitesi, Mart 2019

** İstanbul Aydın Üniversitesi Sosyal Bilimler Enstitüsü, Muhasebe ve Denetimi Ana Bilim Dalı. <https://orcid.org/0000-0003-2453-2223>

*** İstanbul Aydın Üniversitesi Sosyal Bilimler Enstitüsü, Muhasebe ve Denetimi Ana Bilim Dalı. <https://orcid.org/0000-0002-9179-9908>

public companies. Data used in the study to construct the model includes non-finance Turkish companies traded publicly in 1999-2016 period. R statistical language and related machine learning libraries (rpart and partykit) are utilized to train the model. Performance of the model is estimated via cross-validation, a commonly accepted method. The study shows that, the decision tree model applied to the data attains a prediction performance of 91%. Besides being very effective machine learning models for the current scenario, decision trees also appear to be very easy to comprehend and build. It is foreseen that, decision tree models can be utilized by credit analysts at any level and be incorporated to any credit analysis software without much effort.

Keywords: Going concern prediction, decision tree models, non-finance listed companies, Turkey.

GİRİŞ

Şirketlerin finansal süreklilik risklerinin öngörülebilmesi muhasebe bilgi kullanıcıları (yöneticiler, ortaklar, kredi kuruluşları, çalışanlar, potansiyel ortaklar, devlet ve toplum) açısından önemli bir ihtiyaç olarak ortaya çıkmaktadır. İşletmenin genel işleyişi çerçevesinde faaliyetlerini idame ettirebilecek yeterli fonlamayı yaratamaması, yüksek seviyede borçlanması ve borçların ödenmesinde yaşanabilecek güçlükler finansal süreklilik risklerine örneklerdir (Bolak, 2004:9) ve bu durumda işletmelerin faaliyetlerini bir süreye bağlı olmaksızın sürdürebileceği varsayımı (işletmenin sürekliliği kavramı) ortadan kalkabilmektedir (Güredin, 2014:75-76).

Bağımsız denetim raporları işletmelerin finansal süreklilik risklerinin öngörülmesinde faydalı olabilseler de her zaman ve her şirket için üretilememektedirler. Bu raporların finansal süreklilik risklerinin öngörülmesinde ne derece faydalı olabildikleri ise ayrı bir araştırma konusu olarak ortaya çıkmaktadır. Bu ihtiyaçlara kısmi bir cevap vermeyi hedefleyen mevcut çalışmanın temel amacı halka açık finans dışı şirketlerin finansal süreklilik risklerinin bir makine öğrenmesi modeli olan karar ağaçları ile objektif olarak öngörülmesidir.

Bağımsız denetim raporlarının finansal süreklilik riski öngörü performansı kırk yıla yakın bir süredir pek çok araştırmaya konu olmaktadır. 1980'lerde finansal süreklilik riski üzerine yapılan ilk çalışmalarda kredi veren tarafların süreklilik risklerini genelde iyi tayin edebildiği ileri sürülse de, objektif bir model aracılığı ile bağımsız denetçilere bu konuda yardım edilebileceğini

savunan makalelere de rastlanılmaktadır. Bu dönemde halka açık finansal verinin ağırlıklı olarak sadece performans tahmininde kullanıldığı ama bu verinin risk tayininde de kullanılması gerektiği ileri sürülmeye başlamakta, bu öneriler dönemin istatistiki yöntemleri kullanılarak oluşturulan modeller ile de desteklenmeye çalışılmaktadır.

1990'ların başında, finansal süreklilik riski öngörüsü üzerine yapılan çalışmalarda, bağımsız denetçi görüşlerinin başarılı sayılabileceği ve herhangi bir istatistiki yöntem ile bu kararların desteklenmesine gerek olmadığı hala savunulmaktadır (Hopwood ve diğ., 1989:28). Hemen takip eden çalışmalar ise bunun tam zıddını ileri sürmekte, bağımsız denetçilerin finansal süreklilik riski tayinlerinin yetersiz olduğu makalelerde yer almakta ve öncül çalışmaların ulaştığı sonuçlar olumsuz yönde güncellenmektedir (Hopwood ve diğ., 1994:425-426). 1990'ların ortalarından itibaren ise bağımsız denetçilerin sadece mesleki yargıya dayalı batıklık (işletmenin sürekliliği kabulü ortadan kalkmış) öngörüsü performansının %50'den daha düşük olduğu savı ağırlık kazanmaktadır (McKee, 1995:26). 1990'ların sonlarında bu başarısızlığın muhtemel nedenleri irdelenmekte ve bunların ağırlıklı olarak denetim sürecinin gelişmelere ayak uyduramaması ve halka açık bilgiyi tam olarak kullanamaması olduğu ileri sürülmektedir (Lennox, 1999:773-774).

2000'li yılların başlarında yapılan çalışmalarda, denetim raporları ile süreklilik riski arasında doğrusal bir ilişkiden bahsedilebilse dahi, özellikle küçük bağımsız denetim firmalarının gri alandaki finansal süreklilik risklerini ekseriyetle göz ardı edebildiği savunulmaktadır (Gaeremynck ve Willekens, 2003:65). Takip eden çalışmalar ise daha ziyade finansal süreklilik riski tayininde mesleki yargı yanında hangi istatistiki modelin daha başarılı sonuçlar verebileceği üzerinedir.

Son on yıl içinde finansal süreklilik risklerinin öngörülmesi amacıyla denenen modellerin ekseriyeti makine öğrenmesi (machine learning) sınıfına girmektedir. Makine öğrenmesi; bilgisayarlara, özel bir duruma spesifik bir program aracılığı olmadan, öğrenme yetisi kazandırmayı amaçlayan bir bilim dalıdır ve ağırlıklı olarak istatistik ve bilişim teknolojilerinden faydalanmaktadır (Samuel A. L., 1959:211-212). Makine Öğrenmesi modelleri eldeki veriyi kullanarak hem modelin yapısını hem de modelin parametrelerini kendi içinde belirleyebilmektedir.

Karar ağaçları gibi bazı makine öğrenmesi modelleri doğrusal olmayan ilişkilerin kolaylıkla modellenebilmesi yanında, verinin istatistiki dağılımı

üzerindeki geleneksel kısıtlamaları da hafifletilebilmekte ve bu yönleri ile risk tayini modelleri için ideal yapılar olarak ortaya çıkmaktadırlar. Yakın döneme kadar, işlem yoğun tabiatlarından dolayı, pratikte çok fazla uygulama alanı bulamamış olan bu modeller, bilişim teknolojisinde yaşanan gelişmelere paralel olarak, sıkça kullanılan araçlar haline gelmişlerdir. Ortaya çıkan bu teknolojik altyapıdan faydalanarak süreklilik riski modellerinin de güncellenmesi ve geliştirilmesi mümkün görünmektedir. Mevcut çalışma da buna bir örnektir.

Bu makale giriş bölümü hariç, üç bölümden oluşmaktadır. Giriş bölümünü takip eden ilk bölümde çalışmanın amacı, önemi, modelleme aracı ve yöntemi, ana kütle, seçilen örnekleme ve kısıtları yer almaktadır. Çalışmanın ikinci bölümünde analiz ve bulgular aktarılmaktadır. Makalenin son bölümünde ise araştırmanın sonucu ve benzer çalışmalar için öneriler sunulmaktadır.

1. AMAÇ VE YÖNTEM

Bu çalışmanın amacı halka açık finans dışı şirketlerin süreklilik risklerinin, bir makine öğrenmesi modeli olan karar ağaçları ile öngörülmesidir. Süreklilik risklerinin öngörülmesi; fonlama maliyetlerinin belirlenmesi, muhtemel batıklar için karşılık ayrılması ve kaynakların doğru yatırımlara yönlendirilmesi açısından hayati öneme sahiptir. Bu alana yapılabilecek her türlü katkı değerlidir. Kaynakların doğru şekilde kullanılması; mikro seviyede ilgili şirketlerin finansal yapılarının, makro açıdan ise tüm endüstrinin ve genel anlamda da ekonomik büyümenin desteklenmesi anlamına gelmektedir.

Sağlıklı bir süreklilik riski öngörü modeli muhasebe bilgi kullanıcıları (yöneticiler, ortaklar, kredi kuruluşları, çalışanlar, potansiyel ortaklar, devlet ve toplum) açısından önem taşımaktadır. Bu model, bağımsız denetimlerde süreklilik riskinin ortaya çıkarılmasında, yatırım kararlarında finansal riskin ve elde edilmesi gereken minimum verimin tespitinde, işletmede yüksek finansal risk oluştuğunda kurumsal tavrın belirlenmesinde, finansal riskin azaltılması gerektiğinde en doğru yolun seçilmesinde, portföy yönetiminde varlıkların risk açısından sınıflandırılmasında ve alacak portföylerinin kredi riski takibinde kullanılabilecektir.

Bu çalışmada yapılan analizlerin merkezinde bir Karar Ağacı modeli yer almaktadır ve bu model ilk defa Breiman ve diğ. (1984) tarafından Makine Öğrenmesi alanına kazandırılmıştır.

1.1 Karar Ağacı Modeli


Karar ağaçları aslen eldeki verinin sınıflara ayrılmasını hedefleyen makine öğrenmesi modelleri olmakla birlikte, regresyon problemlerinde de kullanılabilirler. Karar ağaçları, özyinelemeli bölümlendirme (recursive partitioning) modelleri ana başlığı altında yer almakta, budaklar (dal ayrımları) ve yapraklardan (sınıflandırmanın belirlendiği nihai duraklar) oluşmaktadır. Özyinelemeli bölümlendirme, makine öğrenmesine dahil ana model sınıflarından biridir ve örnek ana kümesini kendi içinde tekrarlanan biçimde daha saf (tek bir gruba ait örneklerden oluşan) alt gruplara ayırma amacını gütmektedir (Therneau T.M., 1983).

Karar ağaçları, diğer modelleme araçlarına kıyasla, önemli istatistiki üstünlüklere sahiptir. Bunlar; doğrusal bir modele ve eldeki değişkenlerin özel bir dağılımına ihtiyaç duymamasıdır.

Modelin istatistiki üstünlüklerine karşın eğitimi oldukça hesap yoğundur. Çalışmada kullanılan karar ağacının eğitilmesi esnasında budaklarda kullanılacak değişkenlerin tespiti için eldeki tüm değişkenler ve bu değişkenlerin her seviyesi, belirlenmiş hedef kriterler çerçevesinde, tek tek test edilmektedir (greedy search). Bu testlerde en sık başvurulan kriterler ise yaprak saflığı ve doğru sınıflandırma başarısı olarak sıralanabilmektedir.


Bu aşamada, karar ağacı modelinin çalışma prensiplerinin görsel bir sunumu faydalı olabilecektir. Şekil 1'de A (üçgenler) ve B (çemberler) gruplarına ait örneklerin X - Y düzlemindeki dağılımları sergilenmektedir.

Şekil 1: İki Grup Verinin Dağılımı




Örnekleme, karar ağacı modeli ile gruplara ayrılmaya çalışıldığında iki temel ayracın ortaya çıktığı görülmektedir (Şekil 2). İlk ayraç X değişkeni üzerindedir ve herhangi bir örneğin X değeri 4.529'dan küçük ise A grubuna ait olduğu öngörülmektedir. Bu ayraç tek başına 94 örneği sınıflarken sadece 1 örnekte hata yapmaktadır (en sağdaki yaprak).

Şekil 2: Karar Ağacı Modeli Sınıflandırma Öngörüsü



Karar ağacı (Şekil 2) ilk ayracın belirleyemediği örnekler için (X değeri 4.529'a eşit ve daha büyük olanlar için) ikinci bir ayraç daha tayin etmekte ve bu da Y eksenine dayanmaktadır. İlk ayracın sınıflandıramadığı örnekler arasından Y değeri 3.068'den küçük olanların da A grubuna ait olduğu (model bu durumdaki her iki örneği de doğru sınıflandırmaktadır), geri kalanların ise B grubuna ait olduğu öngörülmektedir (104 örnekte 5 hata yapmaktadır).

Şekil 3: Karar Ağacı Ayraçları



Karar ağacı tarafından tespit edilen iki ayraç Şekil 3’te örnek dağılımı üzerine yerleştirilmiştir. X eksenini dik kesen çizgi birinci, Y eksenini dik kesen çizgi ise ikinci ayraç temsil etmektedir.

Tablo 1: Karar Ağacı Modeli Karışıklık Matrisi – Model İçi Performans

		Gerçek	
		A	B
Öngörü	A	%49	%2
	B	%1	%48

Tablo 1’de, eldeki karar ağacı modelinin örnekler için öngördüğü sınıflandırma ve gerçek durum karşılaştırılmaktadır. Bu karşılaştırmaya konu testler model eğitiminde kullanılan veri ile gerçekleştirilmiş olduğundan ulaşılan başarı düzeyi “model içi performans” olarak adlandırılmaktadır (Platt ve Platt, 1990:31). Tablodaki satırlar model öngörüsünü, sütunlar ise gerçek durumu yansıtmaktadır. Örtüşen alanlar (A sütunu ve A satırı, B sütunu ve B satırı) modelin öngörü kabiliyetini, diğer alanlar ise modelin yanlış sınıflandırdığı örnekleri işaret etmektedir. Model içi performans çerçevesinde bakıldığında, bu çok sade iki ayraç, %97’lik bir ekseriyetle (Tablo 1: %49 + %48) iki grubu doğru şekilde birbirinden ayırabilmektedir.

Model içi performans seviyesi, bağımsız örnekler üzerinden hesaplanmadığından, çapraz doğrulama performansı (Jones, 1987:131) kadar sağlıklı bir gösterge değildir, ancak aşırı uygunluğun (model içi performans ile çapraz doğrulama performansı arasındaki fark, Platt ve Platt, 1990:31) tespitinde de önemli rol oynamaktadır.

Bu modelde sadece iki araç kullanılmakta ve araç sayısını artırarak model içi performansı yükseltmek mümkün görünmektedir, ancak bunun aşırı uygunluk problemini ortaya çıkarabileceği de açıktır. Araç sayısı arttıkça karar ağacı modeli eldeki veriye “aşırı uygun” hale gelecek ve bağımsız veri üzerindeki performansı düşebilecektir.

Bu çalışmada aşırı uygunluk probleminde çözüm olarak model kütüphanelerine has karmaşıklık parametresi (cp - complexity parameter) yöntemi takip edilmektedir. Yöntem, yeni araçlara (budaklara) ancak çapraz doğrulama performansı yeteri kadar (cp seviyesinde) yükselebilecekse izin vermektedir. Bunun sonucunda karar ağaçlarının, daha oluşturulurken, aşırı uygun (aşırı büyük) hale gelmeleri engellenebilmektedir.

1.2 Modelleme Yöntemi

Çalışmadaki analizler karar ağacı modelinin eldeki veriye uygulanması ile gerçekleştirilmektedir. Söz konusu model veriye R istatistik dili ve karar ağacına has R kütüphaneleri (rpart ve partykit) aracılığı ile tatbik edilmektedir. Model oluşumunda aşırı uygunluk sorununa karşı karmaşıklık parametresi metodu takip edilmekte ve modelin nihai performansı çapraz doğrulama yöntemi ile tespit edilmektedir.

1.3 Araştırmanın Ana Kütlesi ve Örneklemi

Mevcut çalışmaya 1999-2016 döneminde Türkiye’de yerleşik, halka açık, Borsa İstanbul A.Ş.’de payları işlem gören, finans sektörü dışındaki şirketler dahil edilmektedir. Ciddi süreklilik riski yaşayan şirketlerin tespitinde “finansal zorluklar sebebiyle borsa kotundan çıkarılma” asıl kriter olarak kabul edilmektedir (Gruszczynski M., 2015:96-97).

Finansal zorluklar sebebiyle kottan çıkarılan şirketlerin son sağlıklı bilanço döneminin belirlenmesinde artçı göstergelerden faydalanılmaktadır. Cirodaki hızlı dönemsel düşüşler, piyasa fiyatlarındaki keskin kırılmalar ve döneme ait finansal sorun haberleri artçı göstergeleri oluşturmaktadır. Bu göstergeler şirketin finansal sorunlarının aleni hale gelmesini takiben ortaya çıkmaktadır.

Artçı göstergeler sayesinde şirketin finansal zorluk yaşamadan hemen önceki bilanço döneminin tespiti ve modellemenin bu döneme ait finansal veri ile gerçekleştirilmesi mümkün olmaktadır.

Modellemenin sağlıklı yapılabilmesi için her batık şirket (53 adet) sağlıklı bir diğer şirket ile eşleştirilmektedir. Seçilen sağlıklı şirketlerin batık şirketler ile aynı sektörden olmasına ve bilanço dönemlerinin mümkün olduğunca yakın belirlenmesine dikkat edilmektedir. Bu şekilde 53 adet sağlıklı şirket ve bilanço dönemi tespit edilmekte ve modelin zaman ve sektör yanlılığı en aza indirilmektedir. Toplam örnek sayısı 106'ya ulaşmakta ve sağlıklı/batık dağılımı dengelenmektedir. Çalışmaya konu şirketler 22 farklı sektöre dağılmakta ve örneklem tarihi yayılımı borsa kotundaki şirket sayısına paralellik sergilemektedir.

1.4 Model Değişkenlerinin Belirlenmesi

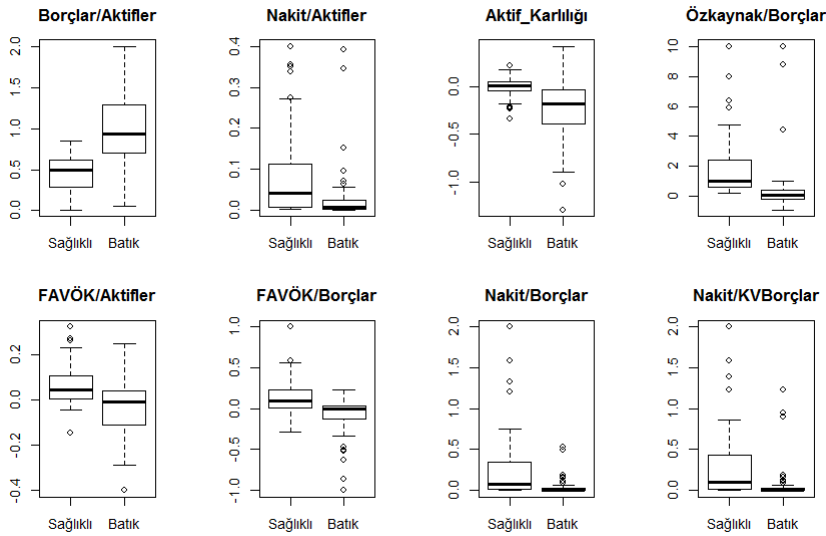
Model eğitiminde kullanılacak değişkenlerin seçimi için benzer çalışmalarda sıklıkla başvurulan göstergeler (Belowary ve diğ., 2007:1-4; Aziz ve Dar, 2006:23; Dimitras ve diğ., 1996) derlenmekte ve ortaya 28 finansal oranlık bir liste çıkmaktadır. 28 değişkenli bir modelin 106 örnek ile aşırı uygunluk sorunu yaşayacağı açıktır ve listenin çalışma hedeflerine yönelik kriterler vasıtası ile kısaltılması gerekmektedir. Bu kriterler; “kararlı”, “sektör yansız” ve “zamanlı” olmak şeklinde sıralanabilmektedir. Örneğin; Fiyat/Kazanç oranı “kararsız” bir göstergedir. Kazanç sıfır civarındayken pozitif sonsuz ve negatif sonsuz arasında salınımlar yapabilmektedir. “Satışlar” kalemi sektör yanlıdır. Satışların aktiflere oranı sektörler arasında büyük farklılıklar gösterebilmektedir. Reel faiz ise “zamanlı” bir gösterge değildir ve gerçek seviyesi bir yıla yakın bir gecikme ile kesinleşmektedir. Bu gecikme, eldeki modelin öngörü ufku (altı ay ve sonrası) kıyasla “uzun” kalmakta ve reel faiz seviyesi model değişkenleri arasında yer bulamamaktadır.

Benzer araştırmalardan derlenen geniş değişken listesi kararlı olma, sektör yansız olma ve zamanlı olma kriterlerine göre sadeleştirildiğinde elde sekiz finansal oran kalmaktadır (Tablo 2). Bu oranların performans, kaldıraç ve likidite etkilerini takip etmeye dönük olduğu görülmektedir.

Tablo 2: Model Eğitimlerinde Kullanılan Finansal Oranlar

Borçlar/Aktifler	FAVÖK/Aktifler
Nakit/Aktifler	FAVÖK/Borçlar
Aktif Karlılığı	Nakit/Borçlar
Öz Kaynak/Borçlar	Nakit/KV Borçlar

Tablo 2’de listelenen değişkenlerin, eldeki örneklem çerçevesinde, batık ve sağlıklı şirketler bazında nasıl dağıldığı Şekil 4’te sergilenmektedir. Dağılımlar arası farkların niceliği ilgili finansal oranların sonuca muhtemel katkısı hakkında ipucu vermektedir.

Şekil 4: Değişkenlerin Hedef Gruplar Bazında Dağılımı


1.5 Araştırmanın Kısıtları

Çalışmada karşılaşılan en önemli kısıt veri hacmidir (106 örnek). Bir modelin belirlemesi gereken parametre sayısı arttıkça ihtiyaç duyulan veri adedi de artmaktadır ve sağlıklı bir model için bu sayının parametre başına ortalama yirmi civarında olması gerektiği ileri sürülmektedir (Goldberger, 1991:249-250).

Çalışmada faydalanılan karar ağacı modelinin her dal ayrımı, değişkenin ve kritik seviyenin tespiti olmak üzere, iki parametrenin belirlenmesini zorunlu kılmaktadır. Bu da dal ayrımı başına yaklaşık olarak kırk örneğe denk gelmektedir. Eldeki örneklemin derinliği 106 olduğundan en fazla üç dal ayrımının ($40 * 3 = 120$) sağlıklı şekilde (ciddi aşırı uygunluk sorunu yaşamadan) belirlenebileceği öngörülmektedir. Bu genel kabulün testi için denenen dört dal ayrımlı model, çapraz doğrulama testleri neticesinde, aşırı uygunluk sebebiyle reddedilmekte ve öngörü teyit edilmektedir.

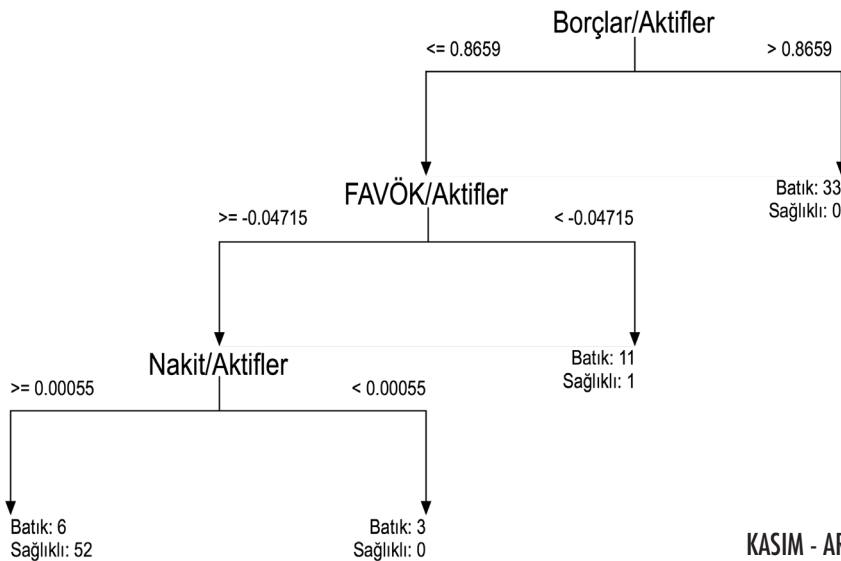
Eldeki örneklemin derinleşmesi halinde daha büyük “sağlıklı” karar ağaçlarına ulaşabilmek mümkün görünmektedir. Bu durumda modelin nihai performansını yapısı değil, veri hacmi belirlemektedir.

2. ANALİZ VE BULGULAR

Karar ağacı modeli eldeki örnekleme tatbik edildiğinde, çapraz doğrulama performansı açısından, optimal karmaşıklık parametresinin %2 seviyesinde belirlenmesi gerektiği görülmektedir. Bu parametre değeri potansiyel ağaçları 3 budağa, yani sadece dört yaprağa sınırlamaktadır.

Karmaşıklık parametresinin %2 olarak belirlendiği durumda ortaya çıkan karar ağacı modeli Şekil 5’te sergilenmekte ve modelin sadece üç değişkeni kullanıp diğerlerini dışladığı görülmektedir. Şekilde işletmenin sürekliliği kabulünün ortadan kalktığı örnekler “Batık”, süreklilik riskinin yaşanmadığı örnekler ise “Sağlıklı” olarak işaretlenmektedir.

Şekil 5: Karar Ağacı Batıklık Öngörüsü Modeli



Şekil 5'teki karar ağacının model içi performansı Tablo 3'te bir karışıklık matrisi aracılığı ile sergilenmekte, burada satırlar model öngörüsünü, sütunlar ise gerçek durumu temsil etmektedir. Öngörü ile gerçek durumun kesiştiği hücreler (%49 + %44 = %93) model içi performansa işaret ederken, bunların dışında kalan hücreler (%1 + %6 = %7) model öngörüsünün başarısız olduğu örnekleri temsil etmektedir.

Tablo 3: Karar Ağacı – Model İçi Performans

		Gerçek	
		Sağlıklı	Batık
Öngörü	Sağlıklı	%49	%6
	Batık	%1	%44

Bu model çerçevesinde sınıflandırma öncelikle eldeki örneğin Borçlar/Aktifler oranı üzerinden gerçekleşmektedir. Bu oran 0.8659'a eşit veya daha yüksek ise örnek muhtemel batık aday olarak sınıflandırılmaktadır (başarı oranı %100). İlk kuralın dışındaki örnekler için FAVÖK/Aktifler oranına bakılmakta, bu oran -0.04715'ten daha düşük ise eldeki örnek yine muhtemel bir batık aday olarak işaretlenmektedir (başarı oranı %92). İlk iki kuralın dışında kalanlar için ise Nakit/Aktifler oranı takip edilmekte ve bu değer 0.00055'ten daha düşük ise eldeki örneğin batık (başarı oranı %100), aksi halde ise sağlıklı olduğu öngörülmektedir (başarı oranı %90).

Karar ağacı modellerinde değişkenlerin sonuca katkısı kaç örneğin sınıflandırmasında rol oynadıkları ile tespit edilebilmektedir. Bu şekilde bir analiz yapıldığında Tablo 4'e ulaşılmaktadır. Tabloda, sonuca en yüksek katkıyı yapan Borçlar/Aktifler oranının ağırlığı normalize edilerek (%100'e eşitlenerek) gösterilmekte, diğer değişkenlerin katkısı buna oranla sunulmaktadır.

Tablo 4: Değişkenlerin Sonuca Katkısı

Değişken Tanımı	En Kuvvetli Değişkene Kıyasla Sonuca Katkısı (%)
Borçlar / Aktifler	100
FAVÖK / Aktifler	44
Nakit / Aktifler	34

Karar ağacı modeli için yapılan çapraz doğrulama testlerinde ise rastgele seçilen 3 örnek dışarıda tutulmakta ve geri kalan örnekler ile bir model oluşturulmaktadır. Daha sonra dışarıda tutulan 3 bağımsız örnek ile bu modelin öngörü performansı belirlenmektedir. Testler bu şekilde 10,000 kere tekrarlanmakta (10,000 model * 3 bağımsız örnek = 30,000 bağımsız öngörü) ve modellerin 27,260 (sonuçlar en yakın 10'a yuvarlanmaktadır) öngöründe başarılı olduğu (%95 güven aralığında %0.3 hata payı ile %91) anlaşılmaktadır. Karar ağacı modelinin aşırı uygunluk sorununun %2 (%93 - %91 = %2) civarında ve kabul edilebilir seviyede kaldığı görülmektedir.

Bulguları genel anlamda derlemek gerekir ise, eldeki model çerçevesinde, sağlıklı bir şirketin özellikleri şöylece sıralanabilecektir: şirketin yaptığı yatırımlara oranla yeterli özkaynağı olmalı, mali performansı “çok kötü” olmamalı ve her zaman bir miktar nakit taşıyabilmeli. Ortaya çıkan model çerçevesinde, eğer şirketin aktiflerine oranla yeterli sermayesi yoksa (borçluluk yüksek ise) veya ciddi miktarda zarar ediyorsa veya elinde neredeyse hiç nakit bulundurmuyor ise, süreklilik risklerinin ciddi seviyede yükselmiş olduğu kabul edilmektedir. Modelin önerdiği birinci kıstas şirketin aşırı borçlu olup olmamasına, ikincisi şirket yönetiminin performansına ve son olarak üçüncüsü de kısa vadeli taahhütlerin karşılanabilmesine odaklanmaktadır.

Bir yönü ile 2001’de Neophytou ve diğ.’nin savundukları nokta teyit edilmektedir: karlılığı, nakdi ve kaldırıcı gösteren üç gösterge gerçekten de batıkların önemli kısmını öngörebilmektedir.

Karar Ağacı gibi sade bir modelin %91’lik çapraz doğrulama performansına erişebilmesi gelecekte yapılabilecek benzer analizler için de ümit vericidir. Model, kolay eğitilebilir, kolay anlaşılabilir ve kolay uygulanabilir özellikleriyle dikkat çekmektedir.

3. SONUÇ VE ÖNERİLER

Bağımsız denetim raporlarının finansal süreklilik riski öngörü performansı 1980’lerden günümüze pek çok çalışmaya konu olmaktadır. Birbirini takip eden bu çalışmalar, mesleki yargı yanında, makine öğrenmesi gibi istatistikî modellerin süreklilik risklerinin tayininde önemli katkılar sağlayabileceği yönünde birleşmektedir. Mevcut çalışmada da, bu tarihi perspektife uygun olarak, bir makine öğrenmesi modeli olan karar ağacının finansal süreklilik risklerini ne seviyede öngörebileceği sorgulanmaktadır.

Çalışmada oluşturulan modellere 1999-2016 döneminde, Türkiye’de yerleşik, halka açık ve finans sektörü dışındaki şirketler dahil edilmektedir. Örneklem toplam 106 şirketten oluşmaktadır (53 batık ve 53 sağlıklı). Her örnek için faaliyet performansını, kaldıracı ve nakit dengesini işaret eden sekiz finansal oran (Borçlar/Aktifler, Nakit/Aktifler, Aktif Karlılığı, Öz Kaynak/Borçlar, FAVÖK/Aktifler, FAVÖK/Borçlar, Nakit/Borçlar, Nakit/KV Borçlar) analizlere dahil edilmektedir. Modellemeler, analizler ve testler R istatistik dili ve ilgili R makine öğrenmesi model kütüphaneleri aracılığı ile gerçekleştirilmektedir. Modellerin performans testleri eldeki örneklerin bağımsız “model” ve “test” gruplarına ayrılması yöntemi (çapraz doğrulama) ile gerçekleştirilmekte ve bu testler yeteri kadar tekrarlanarak (10,000 test ve 30,000 öngörü) elde edilen sonuçların %95 güven aralığında %0.3 hassasiyete erişmesi temin edilmektedir.

Çalışma sonucunda ortaya çıkan karar ağacı modelinin, çapraz doğrulama testleri neticesinde, pratikte ulaşabileceği performansın %91 olduğu ve süreklilik risklerinin tayininde önemli katkılar sağlayabileceği öngörülmektedir.

Karar ağacı kolay eğitilebilir, kolay anlaşılabilir ve kolay uygulanabilir bir model olarak ortaya çıkmaktadır. Modelleme yapmak için eldeki verinin dönüşümlerden geçirilmesine ihtiyaç duyulmamaktadır. Modelin yüksek çapraz doğrulama performansı benzer sınıflandırma problemlerinde de başarı ile kullanılabilmesine işaret etmektedir. Modelin ürettiği sade kuralların güncel risk takibi sistemlerine kolayca eklenilebileceği öngörülmektedir.

Çalışma neticesinde ortaya çıkan model bağımsız denetçilere finansal süreklilik risklerinin öngörülmesi esnasında, mesleki yargı yanında, objektif bir gösterge olarak analiz imkanı sunabilecektir. Mesleki yargının bağımsız denetçiler arasında farklılıklar gösterebileceği kabul edildiğinde, modelin üstlenebileceği bu ikinci göz vazifesi, bağımsız denetim raporlarının yakınsamasına katkı sağlayabilecektir.

Model, bağımsız denetim raporu bulunmayan şirketlerin finansal süreklilik risklerinin tayininde de önemli bir gösterge olarak muhasebe bilgi kullanıcılarının karar mekanizmalarında yer alabilecektir. Yüksek bir öngörü performansına sahip olan model bu alanda önemli katkılar sağlayabilecektir.

Şirketler modelden muhtemel yatırım alternatifleri arasından yüksek riskli olanların ayıklanmasında ve elde kalanlardan daha yüksek verimin sağlanmasında faydalanabilecektir. Bu ayıklama kaynakların daha etkin kullanımını sağlayacak ve aynı zamanda finansal riskleri azaltabilecektir.

Model, şirketlerin kendi finansal süreklilik risklerinin ve riski yaratan asıl unsurların tespitinde de kullanılabilir. Model aracılığı ile finansal riskin ana kaynağı tespit edildiğinde, buna karşı kurumsal tavrın belirlenmesi ve doğru yönde hareket edilmesi de mümkün olacaktır.

Modelin katkı yapabileceği bir diğer alan, alacak portföyüne dahil borçlu şirketlerin kredi riski açısından sınıflandırılmasıdır. Bu şirketler için bağımsız denetim raporlarına ulaşmak genelde mümkün olmamaktadır. Eldeki makine öğrenmesi modeli bu soruna oldukça pratik bir çözüm sunmakta ve sadece üç finansal oran ile temel bir risk sınıflandırması gerçekleştirebilmektedir. Yapılan bu sınıflandırma ile fon akımlarının daha tutarlı bir şekilde belirlenebileceği öngörülmektedir.

Çalışma sonucunda elde edilen model, herhangi bir bağımsız denetim yaklaşımının performans açısından irdelenmesini de mümkün kılmakta ve bu yönde yapılabilecek yeni çalışmalara kapı aralamaktadır. Bağımsız denetim raporlarının süreklilik risklerini ne ölçüde öngörebildiği ve finansal veriyi ne seviyede kullanabildiği eldeki modelden faydalanılarak belirlenebilecektir. Model sadece halka açık veriyi kullanmakta ve bağımsız bir denetçiye kıyasla çok daha dar bir pencereden finansal riskleri sorgulayabilmektedir. Bu şartlar altında, modelin performansı bağımsız denetim raporlarının finansal süreklilik riski öngörü performansı için bir “alt sınır” olarak kabul edilebilecek ve belirlenen bu alt sınırın aşılmasını halinde eldeki bağımsız denetim yaklaşımının güncellenmesi gerekliliği ortaya çıkabilecektir.

KAYNAKÇA

Aziz M. A. ve Dar H. A. (2006). Predicting Corporate Bankruptcy: Where do We Stand? *Corporate Governance: The International Journal of Business in Society*, 6 (1): 18-33.

Belowary J., Giacomina D. and Akers M. (2007). A Review of Bankruptcy Prediction Studies: 1930-Present. *Journal of Financial Education*, 33 (Güz sayısı): 1-42.

Bolak M. (2004). *Risk ve Yönetimi*. İstanbul: Birsen Yayınevi.

Breiman L., Friedman J. H., Olshen R. A. and Stone C. J. (1984). *Classification and Regression Trees*. Monterey: Wadsworth & Brooks / Cole Advanced Books & Software.

Dimitras A., Zanakis S. and Zopounidis C. (1996). A Survey of Business Failures with an Emphasis on Prediction Methods and Industrial Applications. *European Journal of Operational Research*, 90: 487-513.

Gaeremynck A. and Willekens M. (2003). The Endogenous Relationship Between Audit Report Type and Business Termination: Evidence on Private Firms in a Non-litigious Environment. *Accounting and Business Research*, 33 (1): 65-79.

Goldberger A. S., (1991). *A Course in Econometrics*. Cambridge: Harvard University Press.

Gruszczynski M. (2015). Issues in Modelling the Financial Distress and Bankruptcy of Companies. *Quantitative Methods in Economics*, 16 (1): 96-107.

Güredin E. (2014). *Denetim ve Güvence Hizmetleri* 14. bs.. İstanbul: Türkmen Kitabevi.

Hopwood W., McKeown J. and Mutchler J. (1989). A Test of the Incremental Explanatory Power of Opinions Qualified for Consistency and Uncertainty. *The Accounting Review*, 64 (1): 28-48.

Hopwood W., McKeown J. and Mutchler J. (1994). A Reexamination of Auditor Versus Model Accuracy within the Context of the Going-concern Opinion Decision. *Contemporary Accounting Research*, 10 (2): 409-431.

Jones F. (1987). Current Techniques in Bankruptcy Prediction. *Journal of Accounting Literature*, 6: 131-164.

Lennox C. (1999). The Accuracy and Incremental Information Content of Audit Reports in Predicting Bankruptcy. *Journal of Business Finance & Accounting*, 26 (5-6): 757-778.

McKee T. (1995). Predicting Bankruptcy via Induction. *Journal of Information Technology*, 10 (1): 26-36.

Neophytou E., Charitou A. and Charalambous C. (2001). Predicting Corporate Failure: Empirical Evidence for the UK. *University of Southampton, School of Management, Discussion Paper*, 1 (173): 1-30.

Platt H. D. and Platt M. B. (1990). Development of a Class of Stable Predictive Variables: The Case of Bankruptcy Prediction. *Journal of Banking, Finance and Accounting*, 17 (1): 31-51.

Samuel A. L. (1959). Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, 3 (3): 210-229.

Sayın G. (2019). *Halka Açık Finans Dışı Şirketlerde Süreklilik Riskinin Makine Öğrenmesi İle Öngörülmesi*. Yayımlanmamış Doktora Tezi, İstanbul Aydın Üniversitesi.

Therneau T.M. (1983). A Short Introduction to Recursive Partitioning. *Stanford University, Department of Statistics, Orion Technical Report*, 21: 1-11.