

T.C

İstanbul Üniversitesi

Sosyal Bilimler Enstitüsü

PARA, SERMAYE PİYASALARI VE FİNANSAL KURUMLAR
BİLİM DALI

Yüksek Lisans Tezi

Makine Öğrenmesi Yöntemlerinin Temerrüt Oranı İçsel
Derecelendirme Modellerinde Uygulanması

Arda Akı

2501191958

Tez Danışmanı

Prof. Dr. Erdinç Altay

İstanbul 2021

Öz

Ekonomik kriz dönemlerinde finansal sistemin çökmesi tarihte de örnekleri görüldüğü üzere küresel çapta uzun süren ve ağır etkiler bırakmaktadır. Finansal sistemin en önemli unsurlarından biri olan bankaların da olası bir kötüleşen makroekonomik ortamda her zaman hazır durumda olmaları finansal sistemin devamlılığı açısından oldukça kritik bir öneme sahiptir.

Bankaların ekonomik kriz zamanlarını finansal sistemin geneline etki etmeden atlatabilmeleri adına sahip oldukları sermaye miktarları ve yapısı oldukça önemlidir. Bankaların sermaye ve diğer konularda daha güçlü ve sağlam bir hale getirebilmek adına uygulamaya sokulan Basel kuralları, bankalara ne kadar miktarda ve oranda sermaye ayırmaları gereklilikleri gibi çeşitli gereksinimler getirmektedir.

Bankalar için Basel kuralları ile gelen yeniliklerden biri ise, bankaların risk ağırlıklı varlıklar gibi hesaplamaları yapmakta kullandıkları parametreleri kendi içsel modelleri ile hesaplama özgürlüğü getirmeleridir. Bankaların bu bağlamda kendi içsel modelleri ile hesaplayabileceği parametreler başlıca Temerrüt Oranı, Temerrüt Halinde Kayıp ve Temerrüte Maruz Değer olarak öne çıkmaktadır. Bu modeller geçmişe dayalı veri ile kurulan istatistiksel modellerdir.

Çalışmada İçsel Derecelendirme Modelleri ile hesaplanabilen Temerrüt Oranı parametresinin çeşitli makine öğrenmesi algoritmaları ile modellenmesi yapılmış olup sonuçları mevcut uygulama olan Lojistik Regresyon modeli ile de nicel ve niteliksel olarak karşılaştırılmıştır.

Anahtar Kelimeler: Kredi Riski, BASEL Yönergeleri, Makine Öğrenmesi, İçsel Derecelendirme Modelleri

ABSTRACT

Economic turmoil that affects the financial system, results with severe and long termed effects globally as it can also be seen in the past. As one of the most important elements in the financial system, banks always need to be prepared for the worsening macro-economic conditions to maintain the financial stability and prevent a too big to fail event.

Capital structure and the capital amount that banks need to have, play crucial roles to prepare them for such events. In the early 1980s the Basel rules are set by the Basel Committee which is gathered by Bank of International Settlement (BIS) to maintain a strong capital structure for the banks.

As consequences of the Basel 2, banks have the opportunity to calculate the risk parameters such as Probability of Default (PD), Loss Given Default (LGD) and Exposure at Default (EAD) internally to calculate their Risk Weighted Assets which will be further used to determine the amount of capital that they need to set aside according to the Capital Adequacy Ratio which is one of the Basel requirements. These parameters are calculated via internal models of the banks (IRB Models) by using the predictive modeling.

In this study, different machine learning models have been developed and then further assessed both quantitatively and qualitatively with respect to their output performance and their eligibility to be used as IRB PD model respectively and then further challenged against the current practice which is Logistic Regression.

Key Words: Credit Risk, BASEL, Machine Learning, Internal Rating Based Approach

ÖNSÖZ

Finansal sistemin içinde bulunan bütün unsurlar birbirlerine doğrudan bağlantılıdır ve dünyanın herhangi bir yerinde gerçekleşen bir finansal kriz küresel çapta yıkıcı etkiler bırakmaktadır. Finansal sistemi güçlendirmek adına 1980’li yılların başında Uluslararası Ödemeler Bankası (BIS) bünyesinde kurulan Basel Komitesi tarafından çıkartılan Basel yönergeleri ile bankaların içsel parametre hesaplama yöntemlerinde de değişiklikler meydana gelmiştir.

Bankalar Basel 2 yönergeleri sonrasında risk ağırlıklı varlık hesaplamaları yaparken kendi İçsel derecelendirme Modellerinden (IDD Modelleri) yararlanabilmektedir. IDD Temerrüt Oranı hesaplamaları bankalar tarafından mevcutta Lojistik Regresyon algoritması ile hesaplanmaktadır.

Çalışmada mevcut uygulama olan Lojistik Regresyon algoritması diğer makine öğrenmesi algoritmaları ile karşılaştırılmış olup kurulan 4 tane farklı IDD Temerrüt Oranı Modeli, Avrupa Merkez Bankası (ECB) tarafından çıkartılan Kredi Riski Modelleri Validasyonu Raporlaması yönergesinde yer alan nicel kriterler ışığında karşılaştırılmıştır.

Çalışmada ayrıca nicel kriterlerin yanı sıra makine öğrenmesi modellerinin Temerrüt Oranı modellemesi için uygunluğu algoritmaların nitel özellikleri açısından karşılaştırılmaktadır.

Arda Akı
İstanbul
Mart 2022

İçindekiler

Öz.....	ii
ABSTRACT.....	iii
ÖNSÖZ.....	iv
İçindekiler	v
TABLolar LİSTESİ.....	viii
ŞEKİLLER LİSTESİ.....	ix
KISALTMALAR LİSTESİ.....	x
GİRİŞ	11
BASEL SÜREÇLERİ VE 2008 FİNANSAL KRİZİ	13
1.1. 2008 Finansal Krizi	14
1.2. Kredi Riski	17
1.2.1. Kredi Riskinin Çeşitleri	17
1.2.1.1. Verilen Kredi Riski.....	17
1.2.1.2. İhraççı Riski.....	18
1.2.1.3. Karşı Taraf Kredi Riski.....	18
1.2.1.4. Konsantrasyon Riski	18
1.2.2. Beklenen kayıp.....	19
1.2.3. Beklenmeyen Kayıp	20
1.2.4. Kredi Riskinin Temel Bileşenleri.....	22
1.2.4.1. Temerrüt Oranı	22
1.2.4.2. Temerrüt Halinde Kayıp	23
1.2.4.3. Temerrüte Düşen Tutar	25
1.2.5. Risk Ağırlığı Fonksiyonları.....	26
1.3. Basel Uzlaşıları	30
1.3.1. Basel 1	30
1.3.2. Basel 2	31
1.3.3. Basel 3	33
1.3.4. Basel 4.....	36
1.4. Denetleyici Kurumlar Ve Uygulayıcı Merciler	38
1.4.1. Avrupa Bankacılık Otoritesi (EBA).....	39
1.4.1.1. Amacı ve Görevleri.....	39

1.4.1.2.	Bağlayıcı Teknik Standartlar ve Yönergeler	40
1.4.2.	Avrupa Merkez Bankası (ECB)	40
İÇSEL DERECELENDİRME MODELLERİ GEREKSİNİMLERİ VE		
MAKİNE ÖĞRENMESİ ALGORİTMALARI		42
2.1.	Eba Yönergeleri Analizi.....	42
2.1.1.	Temerrüt Tanımı Yönergesi.....	43
2.1.1.1.	Ödememeye Meyillilik Kriteri.....	46
2.1.1.2.	Gecikme Gün Sayısı Kriteri.....	49
2.1.2.	Kriz Dönemi Etkisi Yönergesi	51
2.1.3.	Temerrüt Oranı Modeli Gereksinimleri Yönergesi.....	58
2.2.	TO Modeli Tahminleme Modelleri	62
2.2.1.	Mevcut Uygulama – Lojistik Regresyon	63
2.2.1.1.	Lojistik Regresyon Modellerinin Olumlu Yönleri.....	64
2.2.1.2.	Lojistik Regresyon Modellerinin Olumsuz Yönleri	65
2.2.2.	Alternatif Makine Öğrenme Modelleri	66
2.2.2.1.	XG Boost Modeli.....	66
2.2.2.2.	Rassal Orman	70
2.2.2.3.	K-Means Kümeleme Modeli	72
2.2.2.4.	Destek Vektör Sınıflandırması.....	73
2.3.	Modellerin Karşılaştırılması.....	78
MAKİNE ÖĞRENMESİ YÖNTEMLERİNİN KARŞILAŞTIRILMASI.....		80
3.1.	Çalışmanın Amacı	80
3.2.	Veri Seti	80
3.3.	Kriterler	83
3.3.1.	Ayrıştırıcı Güç.....	84
3.3.2.	Yoğunluk.....	88
3.3.3.	Tahminleme Gücü	90
3.4.	Kriterlerin Önem Derecesi	91
3.5.	Modellerin Analizi	91
3.5.1.	XG-Boost Yöntemi	95
3.5.1.1.	Ayrıştırıcı Güç	96
3.5.1.2.	Tahminleme Gücü.....	96
3.5.1.3.	Yoğunluk	97
3.5.2.	Rassal Orman Modeli.....	97
3.5.2.1.	Ayrıştırıcı Güç	97

3.5.2.2.	Tahminleme Gücü.....	98
3.5.2.3.	Yoğunluk	98
3.5.3.	Destek Vektör Sınıflandırması Yöntemi.....	98
3.5.3.1.	Ayrıştırıcı Güç	99
3.5.3.2.	Tahminleme Gücü.....	99
3.5.3.3.	Yoğunluk	100
3.5.4	Lojistik Regresyon Modeli.....	100
3.5.4.1.	Ayrıştırıcı Güç.....	101
3.5.4.2.	Tahminleme Gücü.....	101
3.5.4.3.	Yoğunluk.....	102
3.6.	MODELLERİN KARŞILAŞTIRILMASI	102
SONUÇ.....		106
Kaynakça		108
Ekler		117

TABLÖLAR LİSTESİ

- Tablo 1** : Temerrüt Tanımı Etkisi Örneđi- Öncesi
- Tablo 2** : Temerrüt Tanımı Etkisi Örneđi- Sonrası
- Tablo 3** : Uzun Dönem Temerrüt Ortalaması Örneđi- Sınıflar
- Tablo 4** : Uzun Dönem Temerrüt Ortalaması Örneđi – Müşteri Bilgileri ve Skor
- Tablo 5** : XGBoost Jeffrey Test Sonucu
- Tablo 6** : Rassal Orman Jeffrey Testi Sonucu
- Tablo 7** : Destek Vektör Sınıflandırması Jeffrey Testi Sonucu
- Tablo 8** : Lojistik Regresyon – Jeffrey Testi Sonuçları
- Tablo 9** : Ayırıştırıcı Güç Karşılaştırması – Özet Tablo
- Tablo 10** : Jeffrey Testi Karşılaştırması – Özet Tablo
- Tablo 11** : Herfindahl Endeksi Özet Tablo
- Tablo 12** : Nicel Araştırma Final Puanları

ŞEKİLLER LİSTESİ

Şekil 1 : Teminatlandırılmış Borç Yükümlülükleri Çalışma Şeması.....	15
Şekil 2 : Riske Maruz Değer Bileşenleri.....	21
Şekil 3 : Uzatılmış Kriz Dönemi Örneği, İşsizlik Oranı Zaman Serisi.....	54
Şekil 4 : Takip Eden Yıllar için Uzatılmış Kriz Dönemi Örneği, İşsizlik Oranı Zaman Serisi.....	55
Şekil 5 : Farklı ekonomik faktörlerin korrele olmaları durumunda uzatılmış kriz dönemi belirleme – GSYH ve Üretim endeksi zaman serileri.....	56
Şekil 6 : Korele makro ekonomik değişkenler ve komşu yıl dip noktası sebebiyle uzatılmış kriz dönemi belirleme.....	57
Şekil 7 : Sigmoid Fonksiyonu ve Grafiği.....	63
Şekil 8 : İkinci Karar Ağacı Çalışma Prensipleri.....	68
Şekil 9 : XG Boost Örneği, İkinci Tahmin Sonucu.....	68
Şekil 10 : XG Boost Modelleri Python Uygulama Kodu.....	69
Şekil 11 : Karar Ağacı Örneği.....	71
Şekil 12 : K-Means Algoritması Çıktı Örneği.....	73
Şekil 13 : Destek Vektör Makinesi Örneği.....	74
Şekil 14 : Destek Vektör Makinesi Algoritması – Aykırı Değer Örneği.....	75
Şekil 15 : Destek Vektör Makinesi Algoritması – Çekirdek Fonksiyon Örneği.....	76
Şekil 16 : Değişkenler arasında korelasyon ısı haritası.....	82
Şekil 17 : Ayrıştırıcı Güç – Sıralama Grafiği.....	84
Şekil 18 : ROC Eğrisi.....	86
Şekil 19 : AUC Hesaplama Kodu - SAS.....	92
Şekil 20 : Herfindahl Endeksi Girdisi – SAS Sorgusu.....	93
Şekil 21 : Herfindahl Endeksi Hesaplama – Excel.....	93
Şekil 22 : Jeffrey Testi Uygulanması - Excel.....	94
Şekil 23 : XGBoost Modeli Kurulumu - SAS.....	95
Şekil 24 : XGBoost AUC hesaplama – Makronun Uygulanması.....	96
Şekil 25 : Destek Vektör Sınıflandırma Algoritması SAS kurulumu.....	99
Şekil 26 : Lojistik Regresyon – SAS Model Kurulumu.....	101

KISALTMALAR LİSTESİ

AIRB	: İleri İçsel Derecelendirme Yöntemi
BCBS	: Basel Komitesi
BDDK	: Bankacılık Denetleme ve Düzenleme Kurulu
BIS	: Uluslararası Ödemeler Bankası
CCF	: Kredi Dönüştürme Parametresi
CDO	: Teminatlandırılmış Borç Yükümlülükleri
CDS	: Kredi Temerrüt Swapı
CRD	: Sermaye Gereksinimi Direktifleri
CRR	: Sermaye Gereklilikleri Düzenlemeleri
EAR	: Raporlama Tarihindeki Risk
EBA	: Avrupa Bankacılık Otoritesi
ECB	: Avrupa Merkez Bankası
EL	: Beklenen Kayıp
FAVÖK	: Faiz, Amortisman ve Vergi Öncesi Kar
GL	: Yönergeler
HI	: Herfindahl Endeksi
IDD	: İçsel Derecelendirme Yöntemi
KGF	: Kredi Garanti Fonu
LAR	: Raporlama Tarihindeki Limit
LKO	: Likidite Karşılama Oranı
NBD	: Net Bugünkü Değer
RAV	: Risk Ağırlıklı Varlık
RTS	: Bağlayıcı Teknik Standartlar
SCRA	: Özel Kredi Riski Ekleme
SYR	: Sermaye Yeterlilik Rasyosu
THK	: Temerrüt Halinde Kayıp
TDT	: Temerrüte Maaruzu Değer
TO	: Temerrüt Oranı
UL	: Beklenmeyen Kayıp

GİRİŞ

2008 Küresel finans krizi sonrasında eksikliği ve önemi daha da anlaşılan, finansal sistem unsurlarında yaşanılacak bir sorunu bir daha benzer bir şekilde küresel çapa yayılmaması için alınan önlemlerin ve bu kararların nasıl uygulanacağını açıklayan yönergelerin bankaların kredi verme kararlarına olan etkileri, bir diğer deyişle içsel kredi riski modellerine olan etkileri ile birlikte bu modellerin hangi şartlar altında en etkin sonucu vereceği araştırılmıştır.

Çalışmanın birinci bölümünde Basel Komitesi (BCBS) tarafından çıkartılan ve asıl amacı finansal sistemi güçlendirmek olan Basel yönergelerinin tarihçesi ve her bir Basel yönergelerinin getirdiği yenilikler ile birlikte etkileri de araştırılacaktır. Basel yönergeleri ile birlikte gelen kavramların tanımlamaları, bu tanımların genel olarak risk ve finansal risk kavramları içerisindeki yeri ve ilişkilerine de yer verilecektir.

Çalışmanın ikinci bölümünde ise Basel yönergeleri ile gelen genel kuralların bankalar tarafından nasıl uygulanacağını açıklayan Avrupa Bankacılık Otoritesi (EBA) tarafından yayınlanan yönergeler incelenecektir. Bu yönergelerin bankaların mevcut İçsel Derecelendirme Modellerine (IDD) olan etkileri getirdiği yenilikler ile birlikte açıklanacaktır. Aynı zamanda bankaların Basel süreçlerine IDD modelleri üzerinden uyumuna ilişkili olarak EBA ve Avrupa Merkez Bankası (ECB) gibi kurumların görevleri ve birbirleriyle olan ilişkileri ve sorumluluklarına da yer verilecektir. Buna ek olarak, bankalar tarafından mevcut olarak kullanılan IDD Temerrüt Oranı modeli araştırılıp, mevcuttaki makine öğrenmesi algoritmasına alternatif olarak başka makine öğrenmesi metotları önerilip, her bir önerilen makine öğrenmesi algoritmasının neden seçilebileceği, iyi veya kötü yanlarının açıklanacağı nitel bir araştırma yapılacaktır.

Üçüncü bölümde, önerilen makine öğrenmesi algoritmaları kullanılacak olan veri setiyle modellenip daha sonrasında ise nicel olarak ECB'nin yönergeleri ışığında valide edilip performans analizleri yapılacaktır. Her bir modelin performansları çıktı analizlerine göre ayrıştırma gücü, sınıflar arasındaki homojenlik gibi çeşitli kriterler ile analiz edilip nicel araştırma bir sonuca ulaştırılacaktır.

Sonu olarak hangi makine ğrenmesi modelinin Temerrüt Oranı (TO) modelleri üzerinde en etkili olduğuna karar vermek amaçlı yapılan nitel ve nicel arařtırmalar sonucunda bir sentez yapılacaktır ve en uygun makine ğrenmesi modeli verilen veri setine göre belirtilecektir.



BİRİNCİ BÖLÜM

BASEL SÜREÇLERİ VE 2008 FİNANSAL KRİZİ

Türkiye Cumhuriyeti Merkez Bankası (TCMB), Çin Merkez Bankası, Almanya Merkez Bankası gibi dünya genelindeki gayrisafi yurtiçi milli hasılasının (GSYMH) %95'ini kapsayan¹ 63 tane ülkenin merkez bankaları tarafından 1930 yılında Basel'de küresel parasal ve finansal istikrarın sağlanmasına katkı sağlama amaçlı kurulan Uluslararası Ödemeler Bankası (BIS) bünyesinde yine aynı amaç için Basel Komitesi (BCBS) kurulmuştur. Basel Komitesi, BIS'in küresel çapta finansal istikrarın devamı amacı doğrultusunda, finansal sistemin temel yapı taşlarından biri olan bankalar için tavsiye niteliğinde çıkarttığı yönergeler Basel Yönergeleri denmektedir. Basel yönergeleri, genel olarak bakıldığında bankaların çeşitli finansal risklere karşı almaları gereken önlemleri, ayırmaları gereken sermaye miktarlarını, sermayenin sınıflandırılmasının ve tanımlamasının yapıldığı maddelerden oluşur. Basel Komitesi, 1974 yılında ortaya çıkmış olup ilk yönergesini – BASEL 1 – 1988 yılında çıkarmasına karşın, özellikle 2008 yılı küresel ekonomik kriz sonrasında mevcutta kullanılan yönergelerin yetersizliğinin anlaşılması üzerine ve Amerika Birleşik Devletleri'nde başlayan krizin küresel bir hal alıp bütün finansal sistemi etkilemesi üzerine bir daha aynı olayları yaşamak istememesinden kriz sonrasında verilen önem iyice artırılmıştır.

2008 Finansal krizi, bankaların kredi riski konusunda ne kadar eksik olduğunun ve Basel kurallarının yetersizliğinin anlaşılması bakımından bir dönüm noktası olmuş ve sonrasında Basel 3 ile başlayarak kredi riski alanında köklü değişimler ve gelişmeler yaşanmıştır. Bu değişimlere ve kredi riski kavramlarına bölümün devamında değinilecektir.

¹ The Bank for International Settlements, About Bis Overview. (Çevrimiçi), (2005, Ocak 1).


1.1. 2008 Finansal Krizi

Kredi Riski kavramının öneminin anlaşıldığı ve bu alan için bir dönüm noktası niteliği taşıyan olaylardan birisi de 2008 Küresel Finans Krizidir. 2007 yılından itibaren Amerika Birleşik Devletleri'nde (ABD) devlet tarafından her ailenin bir ev sahibi olması yönünde özendirilmesi, ev sahibi olmanın orta sınıf ile alt sınıf arasında bir köprü olarak görülmesinden dolayı devletin bankaları konut kredisi vermesi yönündeki teşvikleri için ekonomik krizin ilk adımı denilebilir². Böylelikle konut almaya finansal olarak gücü ve durumu yetmeyen kişiler veya aileler bir konut sahibi olmanın hayaliyle ödeyemeyecek olmalarına rağmen konut kredileri alıp o parayla ev sahibi olmuşlardır. Konutlara olan bu aşırı talep, konut fiyatlarını önceki yıllara göre devamlı bir şekilde artırmış olup, bu artışın sonsuza kadar gideceği izlenimi vermiştir. Bu yanlış izlenim konutlara olan talebi daha da artırmış olup, konut piyasasını bir balon haline getirmiştir. Verdiği müşterinin ödeyip ödeyemeyeceğine bakmadan kredi veren bankalar ise, müşterileri analiz etmek bir yana kredilerden beklenen ödemeler ile oluşturduğu havuzdan bir yatırım aracı oluşturup yatırımcılara satarak likit olmayan bu kredi geri ödemelerini nakde çevirerek daha çok kredi verme alanı bulmuşlardır. 2008 finansal krizi öncesinde kullanımı en çok artan ve kaynağı bankalara bir kere daha kullanma imkânı verdiği için birçok uzmana göre krizin ana sebeplerinden biri olarak gösterilen bu ürünlere Teminatlandırılmış Borç Yükümlülükleri (CDO) denmekteydi. CDO'ların prensiplerini anlatan şema Şekil 1'de gösterilmektedir. Buna göre çeşitli yatırım araçlarının bir araya gelmesi ile oluşturulan havuz aracı kurumlar tarafından risklerine ve getirilerine göre çeşitli gruplara – katmanlara ayrılıp ayrı bir yatırım aracı olarak tekrardan değerlendirilmektedir³.

² Geithner, T. F. (2014). Stress test: reflections on financial crises. First edition. New York: Crown Publishers. ss. 223-246.

³ Mason, Joseph R. and Rosner, Joshua, Where Did the Risk Go? How Misapplied Bond Ratings Cause Mortgage Backed Securities and Collateralized Debt Obligation Market Disruptions ,Mayıs 2007). Print. ss. 33-45.

Şekil 1 : Teminatlandırılmış Borç Yükümlülükleri Çalışma Şeması



Kaynak : Mesut Ayvalı, - (2017, Nisan 17). Collateralized debt obligations (CDO) Nedir? Bireysel Yatırımcı.

Bu durum bankaları ödeyebilip ödeyemeyeceğini bilmeden kredi verdiği müşterilerin geri ödemelerine bağlı olarak oluşturduğu yatırım araçlardan elde ettiği kaynağı bir kez daha kullanabilmeleri anlamına gelmektedir. Bankalar için verilen kredi miktarını artırmak ile beraber aynı zamanda verilen kredilerin geri ödenmeme ihtimalinin zararlarını da yatırımcılara aktaran bu yöntem bankaları kredi verirken risk kavramını iyice arka plana atmasına yol açmıştır.

CDO'lara yatırım yapan yatırımcılar, kısa sürede sermayelerini artırmak için Varlık Destekli Kurumsal Kağıt Piyasasını kullanmaktaydı. Bu piyasada yatırımcılar birbirlerinden bir teminat karşılığında kısa süreli borç alabilmektedir. Ağustos 2007 itibariyle bu piyasanın değeri Avrupa'da 250 Milyar Dolar iken, ABD'de 1.2 Trilyon Dolar seviyesindeydi⁴.

⁴ Murphy, A. (2008). An Analysis of the Financial Crisis of 2008: Causes and Solutions. Structured Markets Equity Derivatives Journal.7(2), ss. 15-22.

2008 Krizi esnasında yatırımcıları tedirgin eden ve mantıklı kararlar almalarına engel olan iki panik dönemi vardır. Bunlardan birincisi Varlık Destekli Kurumsal Kağıt Piyasası'nın çökmesi olarak belirtilebilir. Anlık sermaye artırımını için yatırımcılar tarafından konut kredilerine yaptıkları yatırımları teminat göstererek borç para aldıkları piyasa, konut kredilerinin geri ödenmemesiyle ötürü teminatların değersizleşmesi ile kısa dönemli borç para almak için verilen teminatlar artık kabul görmemeye başlamıştır. Piyasadan borç para alamayan yatırımcıların kısa dönemli fon kaynakları tükenmiş ve kısa dönemde borçlarını birbirlerine ödeyemez olmuşlardır. Piyasadaki bu çöküş ilk panik dönemi olarak nitelendirilir.⁵

ABD'deki 4. en büyük yatırım bankası olan, 639 milyar dolarlık varlıklarıyla ve 619 milyar dolarlık borcuyla Lehman Brothers bankasının 15 Eylül 2008'de iflasını ilan etmesiyle ikinci panik dalgası başlamıştır⁶. Batmak için oldukça büyük olarak nitelendirilen banka iflas ilan ettikten sonra kendisine borcu olan ve kendisinin borçlu olduğu finansal sistemdeki diğer bankaları da ağır bir şekilde etkilemiştir. Domino etkisi yaratan bu iflas, önce ABD'deki finansal sistemi sonrasında ise küresel olarak bütün dünyadaki finansal sistemi etkilemiştir. Öyle ki İzlanda'nın en büyük bankası da Lehman Brothers ile birlikte batan bankalar arasındadır.

Finansal sistemin küresel olarak birbirine bağlılığı, Dünya'nın bir noktasında oluşan bir krizin nasıl bütün her yere yayıldığının aslında bütün finansal sistemin birbirine bağlı olduğunu gösterir niteliktedir. Öyle ki Dünya'nın çeşitli yerlerindeki şirketler başka ülkelerdeki şirketler ile veya başka ülkelerdeki bankalar ile sürekli bir bağlantı halindedirler⁷. 2008 krizi de tek bir bölge bazında değil de küresel boyutta finansal sistemin korunmasının ne kadar önemli olduğunu, bunu sağlayacak bir merci

⁵ Melvin, M., & Taylor, M. P. (2009). The global financial crisis: Causes, threats and opportunities. introduction and overview. *Journal of International Money and Finance*, 28(8), ss. 1243–1245.

⁶ Reddy, K. S., Nangia, V. K., & Agrawal, R. (2014). The 2007–2008 Global Financial Crisis, and Cross-border Mergers and Acquisitions: A 26-nation Exploratory Study. *Global Journal of Emerging Market Economies*, 6(3), ss. 257–281.

⁷ Arestis P. (2016) Main and Contributory Causes of the Recent Financial Crisis and Economic Policy Implications. *Emerging economies during and after the Great Recession* (1st ed.). Palgrave Macmillan UK :Imprint: Palgrave Macmillan., ss. 1-36.

ve kurallar olmasının gerektiğini ve Dünya'nın bir bütün olarak bu kurallara uymasının ne kadar büyük önem arz ettiğini göstermiştir.

2008 krizinin göstermiş olduğu bir başka nokta ise hali hazırda o dönemde aynı amaçla bulunan düzenlemelerin ve kuralların küresel bir krizi önlemede yetersiz olduğunu, daha mantıklı ve birbirini destekleyen kurallar koymanın gerekli olduğunu gösterir nitelikte olmuştur. Lehman Brothers o dönemde uygulanan Basel 2 kurallarına uyumlu olduğu halde iflasını ilan etmesi gibi etkenlerin sonucu olarak o dönemde uygulanan Basel 2 kurallarının üstüne Basel 3 kuralları getirilmiştir. Basel yönergelerinin detaylarına ilerleyen bölümlerde değinilecektir.

1.2. Kredi Riski

Genel olarak bakıldığında borç para alan yükümlünün yükümlülüklerini yerine getirememesi olarak tanımlanan⁸ Kredi Riski kavramı özellikle 2008 krizinin en temel sebepleri arasında yer almaktadır. 2008 krizinden önce de Basel kuralları ile değinilen bu konu, Lehman Brothers'ın belirlenen Basel 2 kurallarına göre uyumlu olmasına rağmen yine de batmış olmasıyla yetersiz olduğu anlaşıp, 2008 krizi Kredi Riski alanı için bir dönüm noktası haline gelmiş ve yeni düzenlemeler ortaya çıkmıştır. Kredi Riski çeşitlerine ve kaynaklarına göre kendi içinde dörde ayrılmaktadır.

1.2.1. Kredi Riskinin Çeşitleri

1.2.1.1. Verilen Kredi Riski

Bir kredi verilmesi durumunda, verilen krediye ait olan ana para miktarı ve faiz miktarının zamanında ödenmemesinden kaynaklanan kredi riskine verilen kredi riski denmektedir⁹. Verilen kredi riski adından da anlaşılabilceği üzere kredi veren kurum tarafından yapılan analizler sonucu verilen kredinin, kredi verilen kişi tarafından geri ödenememe riskine yapılan bir tanımlamadır. Çalışmada makine öğrenmesi yöntemlerinin bankaların temerrüt oranı modellerine etkileri araştırılacağından ve

⁸ Joseph, C. (2013). Credit Risk Management. Advanced Credit Risk Analysis and Management, Basılı ss. 27-34.

⁹ A.e. Joseph ss. 27-34.

bankaların en çok maruz kaldığı kredi riski, verilen kredi riski olduğundan çalışmanın diğer bölümlerinde de bahsi geçen kredi riski ‘verilen kredi riski’ olacaktır.

1.2.1.2. İhraççı Riski

Kredi riskinin bir diğer çeşidi olan ihraççı riski, bir menkul kıymeti ihraç eden kişinin, o menkul kıymete konu olan ödemeleri gerçekleştirememesinden kaynaklanır. Menkul kıymetler yapıları gereği kupon ödemelerine ve vade sonunda bir miktar ödemesi gerektirebilirler. Menkul kıymetleri çıkartan kurumun amacı, fon ihtiyacını karşılamak olup menkul kıymet çıkartarak kendisine gereken fon ihtiyacını karşılayıp menkul kıymetin kendisine yüklediği kupon ve nominal değer ödemesini de vadesinde yapması gereklidir. Zamanında yapamadığı ve yükümlü olduğu kupon ve vade sonu ödemeleri menkul kıymete yatırım yapan kurum veya kişiler tarafından kredi riski olarak görülür, ve ihraççının bu planlanan ödemeleri zamanında yapamaması İhraççı riski olarak adlandırılır.¹⁰

1.2.1.3. Karşı Taraf Kredi Riski

Karşı taraf kredi riski her iki tarafa da yükümlülük getiren bir işlemin muhatabı olan karşı tarafın, bu işlemin nakit akışında yer alan son ödemeden önce temerrüde düşme riskini belirtmektedir.¹¹

1.2.1.4. Konsantrasyon Riski

Verilen kredilerin bir alanda yoğunlaşmasından ortaya çıkacak geri ödeyememe riskine denir Belirli ortak davranışları paylaşan, benzer karakteristiklere sahip olan, aynı ekonomik atmosfere maruz kalan şirketler veya ülkelere kredi verirken yoğunlaşmasından kaynaklanan, ortak paydada kötüye giden bir etkenin bütün diğer şirketlere de etki etmesinden ötürü yoğunlaşmanın getireceği riske denilmektedir.¹²

¹⁰ Capeci, J. (1991). Credit risk, credit ratings, and municipal bond yields: A panel study. National Tax Journal, 44(4.1), ss. 41–56.

¹¹ TBB, Türkiye Bankalar Birliği. (2011). (publication). Bankaların Sermaye Yeterliliğinin Ölçülmesine Ve Değerlendirilmesine İlişkin Yönetmelik. İstanbul, Resmi Gazete: TBB.

¹² Basel Committee On Banking Supervision International Organization Of Securities Commissions International Association Of Insurance Supervisors. 1999, Aralık. Risk concentrations principles. Çevrimiçi.

1.2.2. Beklenen kayıp

Bir bankanın verdiği kredilerden geri dönmesini beklemediği, bir diğer deyişle kaybetmeyi beklediği kayıplara beklenen kayıp denir¹³. Buna göre bankalar verdikleri kredi başına müşterinin temerrüt olasılığını, kredi risk miktarını ve temerrüt halindeki kayıp miktarlarını ve kredinin vadesini göz önüne alarak bir beklenen kayıp hesaplarlar. Bu beklenen kayıplara iş yapmanın bedeli de denilebilir, öyle ki bankalar bu kayıpları işin doğası gereği gözden çıkarırlar ve ona göre zaten tedbirlerini alırlar. Beklenen kayıp miktarları bahsedilen parametreleri kullanarak Uluslararası Finansal Raporlama Standartları 9 (UFRS 9) kuralları çerçevesinde hesaplanmaktadır. Bu kurallara göre beklenen kayıplarının, ürünlerin temerrüt oranları etrafında birinci, ikinci ve üçüncü aşamaya atanmalarıyla hesaplanmaları gerektiği ve hangi faiz oranı ile indirgemelerin yapılması gerektiği gibi konulara açıklık getirmektedir.¹⁴

UFRS9 kriterlerine göre birinci sınıfta bulunan ürünler bankaların çok fazla kayıp beklemedikleri ve risklerinin düşük olduklarını düşündükleri çok fazla önlem gerektirmeyen ürünlerden oluşmaktadır. Öte yandan ikinci sınıftaki ürünler belirli olayla ile birinci sınıftan ikinci sınıfa yükselmiş, daha detaylı beklenen kayıp hesabı istenilen daha çok dikkat edilmesi gereken ürünlerden oluşmaktadır¹⁵. Üçüncü sınıfta ise temerrüte düşmüş ürünler bulunmaktadır. Buna göre ikinci sınıfta bulunan ürünler için, ürünün bütün vadesi boyunca her yıl için bir temerrüt oranı hesaplanıp ona göre yıllık bir beklenen kayıp hesaplaması yapılması gerekmektedir. Daha sonra ürünün vadesine kadar olan beklenen kayıp miktarları toplanıp o ürün için toplam beklenen kayıp bulunabilmektedir. Bir ürünün ikinci sınıfa geçmesi belirli kriterlere bağlıdır. Bu kriterler başlıca¹⁶ :

¹³ Nahit Özen, Gelişen Piyasa Koşullarında Krediler ve Kredilendirme Süreci, Türkiye Bankalar Birliği Eğitim Merkezi Seminer Notları, Şubat 2009.

¹⁴ Novotny-Farkas, Z. (2016). The interaction of the IFRS 9 expected loss approach with supervisory rules and implications for Financial Stability. Accounting in Europe, 13(2), ss. 197–227.

¹⁵ Bankacılık Düzenleme ve Denetleme Kurumu: (2018) TFRS 9 Uyarınca Beklenen Kredi Zarar Karşılığı Hesaplamasına İlişkin Rehber, s. 14.

¹⁶ PWC. (n.d.). IFRS 9 understanding the basics - PWC: Audit and assurance. (Çevrimici) Kasım 27, 2021.

- Temerrüt oranındaki belirgin yükseliş
- Ürünün yeniden yapılandırmaya girmesi
- Ürünün gözetleme listesine alınması
- Konut kredilerinde ödeme erteleme

Olarak belirtilebilir. Bu durumlardan herhangi birisinin görülmesi halinde ürün birinci sınıftan ikinci sınıfa geçirilip vadesine kadar her yıl için beklenen kayıp miktarı hesaplanmaktadır.

UFRS9 modellerinde beklenen kayıp hesaplamalarında dikkat edilmesi gereken diğer noktalar ise modellerin anlık makroekonomik koşullardan etkilenmeleridir. Öyle ki modeller içinde bulunan makroekonomik değişkenler ile değişen koşullarda farklı sonuçlar hesaplayıp o anki duruma göre sonuçlar vermektedir¹⁷.

1.2.3. Beklenmeyen Kayıp

Bir bankanın iş yapmasının bedeli olan kayıplardaki bir diğer deyişle beklenen kayıplarındaki sapmaya beklenmeyen kayıp denmektedir¹⁸. Özellikle ekonomik kriz gibi beklenmedik makroekonomik durumlardaki kötüleşmelerden doğan beklenen kayıplardaki sürekli değişime ve kötüleşme beklenmedik kayıpları önemli ölçüde etkilemektedir.

Bir bankanın beklenmeyen kayıplara karşı alacağı önlemlerin başında sermaye ayırımı gelmektedir. Kriz dönemleri gibi zamanlarda bankalar hesapta olmayan kayıpları kendi sermayelerinden ayırdıkları miktarlar ile telafi edip, krizin küresel çapa yayılmasını engellemeyi amaçlarlar. Beklenmeyen kayıplar için ayrılan sermaye

¹⁷ Lopez, Jose A., 2004. "The empirical relationship between average asset correlation, firm probability of default, and asset size," Journal of Financial Intermediation, Elsevier, vol. 13(2), ss. 265-283.


¹⁸ Krebs, M., & Nippel, P. (2021). Unexpected loss, expected profit, and economic capital: A note on economic capital for credit risk incorporating interest income, expenses, losses, and Roe Target. Finance Research Letters, s. 38.

miktarları risk ağırlıklarına ve bankaların risk ağırlıklı varlıklarının miktarlarına göre belirlenmektedir.

Bankaların beklenen kayıpları ile beklenmeyen kayıplarının toplamı, bankanın riske maruz değerini göstermektedir. Buna göre bankalar belirli bir güven aralığında beklenen ile beklenmeyen kayıplarının toplamı ile yaşayabilecekleri tüm zararları belirtmiş olurlar. Riske maruz değerden daha fazla olan potansiyel kayıplar ise yıkıcı kayıplar olarak nitelendirilmektedir.¹⁹

Beklenen kayıplar, beklenmeyen kayıplar ve riske maruz değer arasındaki ilişki Şekil 2 de özetlenmiştir²⁰.

Şekil 2 : Riske Maruz Değer Bileşenleri



Kaynak : Basel Committee on Banking Supervision. (n.d.). An Explanatory Note on the Basel-II IRB Risk Weight Functions

¹⁹ A.e. Krebs, M., Nippel, P. (2021).

²⁰ Basel Committee on Banking Supervision. (n.d.). An Explanatory Note on the Basel II IRB Risk Weight Functions . (Çevrimiçi).

1.2.4. Kredi Riskinin Temel Bileşenleri

Kredi Riski'nin miktarsallaştırılması ve ölçülmesinden ile birlikte bu riskin yönetilmesi için de belirli tanımlamalara ve göstergelere ihtiyaç vardır. Temerrüt Oranı, Temerrüt Halinde Kayıp ve Temerrüte Maruz Değer kavramları kredi riskinin miktarsallaştırılması adına en temel üç bileşen olarak öne çıkmaktadır. Bölümün devamında bu üç kavrama değinilecektir.

1.2.4.1. Temerrüt Oranı

Temerrüt Oranı (TO), kredi verilen ve bu krediyi anapara ve faiziyle birlikte geri ödemeye yükümlü olan kişinin ödemelerinin anaparasını veya faizini kredi veren kuruma veya kişiye geri ödeyememe ihtimaline denir²¹. Yükümlünün borcunu geri ödeyememesindeki temel faktörler önceki kredi kalitesi, gelir miktarı gibi değişkenler ile bankaların kendi içsel modelleriyle hesaplanabilmektedir. Bankalar krediye başvuran müşterilerin temerrüt oranlarını hesaplamak için daha önceden benzer özelliklerdeki müşterilerin verilen kredilerde nasıl davrandıklarından yola çıkmaktadırlar – dolayısıyla istatistiksel yöntemler ile geçmiş bilgidan geleceğe dair çıkarımlarda bulunurlar. Bu açıdan bankaların geçmiş bilgileri nasıl tuttuğu ile veri kalitelerinin ne kadar iyi olduğu en önemli etkenler arasındadır. Sonuç olarak geleceğe dair çıkarımda bulunulacak veri bankanın yine kendi verisidir. Bazı durumlarda bankalar kriter belirlemek için dış veriye de başvursalar da, temel de modellerin kurulumu için içsel – kendi verisi en önemli pozisyonudur.²²

Temerrüt oranı bankalarda çeşitli analizlerde kullanılabilmektedir. Bu analizlerin başında aşağıdaki hesaplamalar gelmektedir²³:

- Risk Ağırlıklı Varlıkların hesaplaması
- Beklenen Kayıplar için karşılık hesaplaması
- Kredi kabul süreçlerine bakılması

²¹ Fernandes, J. (2005). Corporate credit risk modeling: Quantitative rating system and probability of default estimation. SSRN Electronic Journal. ss. 3-10.

²² Lopez, Jose A. & Saidenberg, Marc R., 2000. "Evaluating credit risk models," Journal of Banking & Finance, Elsevier, vol. 24(1-2), ss. 151-165.

²³ A.e. Basel Committee on Banking Supervision.

Bankalar bir müşterinin temerrüt oranından bu gibi kritik değerleri ve hesaplamaları yapmaktadırlar. TO'nun ne kadar iyi ölçüde hesaplandığı bankaların ne derecede isabetli bir miktarda sermaye ayırdıklarını etkilemektedir. Yanlış hesaplanan TO değerleri bankaların gereksiz yere sermaye ayırmasına veya daha kötüsü gerekenden daha az sermaye ayırmasına sebebiyet verebilmektedir. İkinci olasılık bir diğer deyişle daha az ayırma- iyimserlik daha riskli olabilmektedir çünkü gerekenden az sermaye ayırmak veya temerrüte düşecek bir müşteriye kredi vermek bankanın ve finansal sistemin istikrarını tehlikeye atmaktır. Öte yandan daha konservatif olmak bir diğer deyişle gerektiğinden daha dikkatli olup daha fazla sermaye ayırmak da bankanın daha kar getiren işlerde kullanabileceği para miktarını yok yere sermaye olarak tutup herhangi bir şekilde değerlendirememesine sebebiyet vermektedir. Bu açıdan olabildiğince isabetli miktarlarda sermaye tutmak bir diğer deyişle ona göre TO parametresini hesaplamak bankalar açısından oldukça önemlidir.²⁴

Bankaların TO değerlerini ve diğer parametrelerini olabildiğince isabetli hesaplamaları için her şeyden önce bütün, tamamlanmış ve olabildiğince güncel tutulmuş bir veri sistemlerinin olmaları gerekmektedir. Gerçeği yansıtmayan doğru ve yeterli bilgileri barındırmayan bir veri sistemi ne kadar iyi bir model kurulmaya çalışılırsa çalışılırsın yine de yanlış ve aldatıcı bir sonuç verecektir. Bu açıdan veri sistemi ve altyapısı bankalar için en önemli unsurlardan biridir.²⁵

1.2.4.2. Temerrüt Halinde Kayıp

Temerrüt Halinde Kayıp (THK) oranı, bir müşterinin temerrüte düştükten sonra bankanın müşteride mevcut olan riskinden ne kadarını geri toplayamayacağını dolayısıyla ne kadarını kayıp olarak kayıtlarına geçireceğinin tahmin edilmesidir. Müşteri temerrüte düştükten sonra, müşterinin mevcutta sahip olduğu bütün riskleri kayıp olarak gerçekleşmez. Bankalar verecekleri krediler karşılığında çeşitli teminatlar alabilirler. Bu teminatları alma sebepleri müşterinin olası bir geri ödeyememe durumunda kayıplarını bu teminatları kullanarak olabildiğince az seviyeye indirmek istemeleridir. Bankaların olası bir temerrüt durumunda krediyi verirken almış olduğu

²⁴ A.e. Lopez.

²⁵ A.e. Lopez.

teminatları kullanarak zararını telafi etmesinde dikkat edecekleri en önemli unsurlardan biri de teminatların ne kadar çabuk ve ne kadar değer kaybetmeden nakit hale dönüşebileceğidir, bir diğer deyişle teminatların likiditesidir. Teminatlar likiditelerine göre sınıflara ayrılmaktadırlar. Bu sınıflar ülkelerden ülkeye yerel düzenleyiciler tarafından değişiklik gösterse de Türkiye için, 22 Haziran 2016 tarihli 29750 sayılı Resmi Gazete’de belirtildiği üzere²⁶ aşağıda örneklendirilmiştir:

Grup 1 Teminatları:

- Mevduatlar, altın hesapları, kredi kartı alacakları
- Kira sertifikaları
- ECB kefaletiyle kullanılan borçlanma araçları
- Repo işlemleri sonucunda elde edilen kaynaklar

Grup 2 Teminatları:

- Altın dışında kalan kıymetli madenler
- Teminat mektubu, garanti, aval, kefalet
- Borsada işlem görüyor olan pay senetleri
- Temerrüte karşı koruyan kredi türevi ürünleri, örneğin Kredi Temerrüt Swapı (CDS)
- Kredi Garanti Fonu (KGF) haricinde olan kefaletler

Grup 3 Teminatlar:

- Gayrimenkul ipotekleri (özellikle konut kredileri için)
- Borsada işlem görmeyen pay senedi

Grup 4 Teminatları:

- Taşıt rehini
- Gemi veya uçak ipoteği
- Kefaletler, alacaklar, senet veya çekler

²⁶ Başbakanlık Mevzuatı Geliştirme Ve Yayın Genel Müdürlüğü. (n.d.). Çevrimiçi. Eylül 12, 2021.

Grup 5'e dahil olan teminatlar ise, diğer 4 gruba dahil olmayan kalan teminatlar olarak sınıflandırılmaktadır. Bu teminat sınıflara göre bankaların modelleri sonucunda her bir ürün için hesaplanan bir THK oranı bulunmaktadır.

Bankalar kendi içsel THK'lerini hesaplama amaçlı kurdukları içsel derecelendirme THK modellerini hesaplarken 2 genel yaklaşımı kullanmaktadırlar, bunlardan birisi saç kesimi yaklaşımı iken diğeri ise geri toplama yaklaşımı olarak belirtilebilir.

Buna göre Saç kesimi yaklaşımında modelleme temel olarak teminatın gerçek fiyatı ile satılan fiyatı arasındaki fiyat farkını baz alarak bir öğrenme ve sonrasında ise hesaplama yaparken, geri toplama modelinde ise teminatların likiditesine bağlı olarak bir öğrenme ve hesaplama yapılmaktadır.²⁷

1.2.4.3. Temerrüte Düşen Tutar

Kredi Riski alanında yapılan hesaplamalarda kullanılan bir diğer temel kavram ise Temerrüte Düşen Tutar'dır (TDT). Beklenen zarar veya ayrılması gereken sermaye hesaplamaları yaparken bir ürünün temerrüte düştüğü anda ne kadar bir tutarla temerrüte düştüğü de hesaplamalıdır²⁸. Sonuç olarak bir ürünün raporlama tarihindeki veya şundaki mevcut bulunan tutar ile tahmini temerrüte düşme tarihinde sahip olacağı tutar aynı olmayacaktır. Zaman içerisinde bu riskin artması beklenmektedir. TDT hesaplamaları limit boşluğu bulunan ürünler için hesaplanır. Örnek vermek gerekirse Kredi Kartları veya Kredili Mevduat Hesapları (KMH), TDT hesaplamaları için uygun ürünlerdir. Bu limitlerde raporlama tarihindeki risk (EAR) ile, raporlama tarihindeki limit (LAR) arasında fark bulunacağından bir diğer deyişle limit boşluğu bulunacağından, temerrüt tarihindeki risk tutarı ile de raporlama tarihindeki risk tutarı arasında da bir fark beklemek mantıklı bir düşüncedir. Limit boşluğu bulunan ürünlerde TDT miktarları kredi dönüştürme parametreleri (CCF) üzerinden hesaplanır. Belirli risk özellikleri ile bir IDD modeli kurulabilir ve bu model yardımıyla her bir ürün için veya portföy geneli için istatistiksel olarak tahmini bir kredi dönüştürme faktörü hesaplanmaktadır. Bu tahmini hesaplanan kredi dönüştürme faktörü, daha sonra

²⁷ Cossin, D., & Hricko, T. (2003). A structural analysis of credit risk with risky collateral: A methodology for haircut determination. *Economic Notes*, 32(2), ss. 243–282.

²⁸ A.e. Basel Committee on Banking Supervision.

portföyde bulunan ürünler için, raporlama tarihindeki miktar ve mevcut limit boşluğu kullanılarak, aşağıdaki formül yardımıyla, tahmini bir temerrüte düşme miktarı hesabında kullanılır.

$$TDT = EAR + (LAR - EAR).CCF$$

Basel yönergeleri gereği TDT hesabında kullanılan istatistiksel modellerde belirli şartlar ve gereksinimlerin sağlanması gerekmektedir. Ancak araştırmanın konusu TO modelleriyle sınırlı kaldığından ötürü bu gereksinimlerin detaylarına girilmeyecektir. Diğer limit boşluğu bulunmayan ürünler için ise TDT miktarı raporlama tarihindeki risk miktarına eşittir. Bu tip limit boşluğu bulunmayan ürünlerde raporlama tarihindeki riskin limit tarihine kadar artması ihtimali bulunmadığı için, raporlama tarihindeki değeri doğrudan almak uygun bir metodoloji olarak kabul edilmektedir. Zaman içinde riski azalan, bir diğer deyişle raporlama tarihi ile temerrüte düşme tarihi arasında riski azalan ürünler ise kredi dönüştürme faktörü sıfır olarak kabul edilerek model geliştirme veri setine alınır.²⁹

1.2.5. Risk Ağırlığı Fonksiyonları

Finansal sistemdeki istikrarın sağlanması amacıyla ortaya çıkan Basel kurallar ile gelen en önemli yenilik kuşkusuz sermaye oranı gereksinimidir. Buradaki amaç olası bir kötü senaryoda bankanın durumu telafi edecek ve finansal sistemin bütününe yayılmasını engelleyecek bir sermaye tamponu oluşturulmasının sağlanmasıdır. Sermaye gereksiniminin ana bileşenlerinden birisi de bankanın sahip olduğu toplam risk ağırlıklı varlık tutarıdır. Bankanın toplam risk ağırlıklı varlık tutarı aslında bankanın sahip olduğu varlıkları risk ağırlıkları ile ağırlandırarak toplam almaktan başka bir şey değildir. Sonuç olarak Risk Ağırlıklı Varlık'taki 2 temel bileşen risk ağırlığı ve varlığın miktarıdır. Varlığın miktarı bankanın verdiği krediler sonrasında girdiği riskin (TDT), bu varlıkları risk ağırlıkları ile ağırlıklandırırken Standard yöntem kullanılması durumunda her bir varlık grubu için belirli risk ağırlıkları varken, IDD yöntemi kullanıldığında varlık grupları için bütün bankalarda aynı değer kullanılmamaktadır. IDD yöntem kullanarak parametrelerini hesaplayan (TO, THK;

²⁹ European Banking Authority. (2021, Haziran 1). Estimation of credit conversion factor in case of exposure values decreasing before default event. Çevrimiçi, Kasım 28, 2021.

TDT gibi) bir banka için her bir portföyün risk ağırlığı da bu parametrelere göre belirlenir. Her bir portföy için IDD yaklaşımında risk ağırlıklarının nasıl belirleneceği, BIS tarafından çıkartılan kredi riski için sermaye yeterlilikleri yönergesinin Kredi Riski için RAV hesaplamaları³⁰ kısmında bahsedilmektedir. Yönergeye göre bankalar aşağıda belirtilen portföyler için ayrı ayrı risk ağırlıkları hesaplamalıdır.

- Kurumsal Şirketler, hükümetler ve diğer bankalara verilen krediler
- Bireysel Konut kredisi müşterileri
- Bireysel rotatif kredi müşterileri
- Diğer bireysel krediler

Her bir portföyün risk ağırlıkları için formüller değişkenlik gösterse de kullanılan parametreler genellikle benzerlik göstermektedirler. BIS tarafından çıkartılan, genel Basel çerçevesi adı altında toplanan belgeler bütünün kredi riski için RAV hesaplaması dokümanında³¹ belirtilen denklemler aşağıda gösterilmektedir. Bu denklemlerde geçen $N(x)$ normal dağılımda bir rassal değişkenin verilen x sayısına eşit veya daha küçük olma ihtimaline, $G(z)$ gösterimi ters normal dağılım için z oranını veren rassal değişkene, R değişeni portföyler içerisindeki müşterilerin birbirleriyle olan korelasyonuna, K değeri ayrılması gereken sermaye miktarına işaret etmektedir.

³⁰ BIS. (n.d.). Cre - calculation of rwa for credit risk. The Bank for International Settlements. Çevrimiçi, Eylül 2021.

³¹ Basel Committee on Banking Supervision. (2005, Temmuz). An Explanatory Note on the Basel II IRB Risk Weight Functions. Çevrimiçi, Nisan 2021.

Buna göre, kurumsal şirketler, hükümetler ve yerel yönetimlere verilen krediler için hesaplanması gereken Risk ağırlığı formülü aşağıda gösterilmektedir.³²

$$\left[THK \cdot N \left[\frac{G(TO)}{\sqrt{(1-R)}} + \sqrt{\frac{R}{1-R}} \cdot G(0.999) \right] - TO \cdot THK \right] \cdot \frac{(1 + (M - 2.5) \cdot b)}{(1 - 1.5 \cdot b)}$$

THK : Temerrüt Halinde Kayıp Oranı

TO : Temerrüt Oranı

G(.) : Ters Standart Normal Dağılım

R: Varlık Korelasyonu

K: Sermaye Gereksinimi

M: Vade eklemesi

b: Düzenleştirilmiş vade eklemesi

Burada dikkat edilmesi gereken diğer konular, formüldeki portföye özel korelasyon (R) ve düzenleştirilmiş vade eklemesi (b) parametrelerinin bu portföy için nasıl hesaplanacağıdır. Her bir varlık sınıfı için farklı olarak hesaplanabilen bu parametrelerin nasıl hesaplanacağı aşağıda gösterilmektedir.³³

$$R = 0,12 \cdot \frac{(1 - e^{-50 \cdot TO})}{(1 - e^{-50})} + 0,24 \cdot \left(1 - \frac{(1 - e^{-50 \cdot TO})}{(1 - e^{-50})} \right)$$

$$b = [0,11852 - 0,05478 \cdot \ln(TO)]^2$$

TO : Temerrüt Oranı

R: Varlık Korelasyonu

b: Vade eklemesi

³² A.e. Basel Committee on Banking Supervision.

³³ A.e. Basel Committee on Banking Supervision.

Aynı şekilde, diğer portföyler için risk ağırlığı ve diğer parametrelerin nasıl yapılması gerektiğine dair hesaplamalar aşağıdaki denklemlerde belirtilmiştir. Konut kredileri için korelasyon 0.15 olmak üzere sabit olarak alınırken, bireysel rotatif krediler için bu rakam 0.04 olarak belirlenmiştir. Buradan da aslında konut kredileri müşterilerinin makroekonomik koşullardan daha çok etkilendiklerini ve birbirlerine ve finansal sisteme daha çok dayandıkları çıkartılabilmektedir.

$$K = \left[THK \cdot N \left[\frac{G(TO)}{\sqrt{(1-R)}} + \sqrt{\frac{R}{1-R}} \cdot G(0.999) \right] - TO \cdot THK \right]$$

THK : Temerrüt Halinde Kayıp Oranı

TO : Temerrüt Oranı

N(.) : Standart Normal Dağılım

G(.) : Ters Standart Normal Dağılım

R: Varlık Korelasyonu

K: Sermaye Gereksinimi

Denklemlerden de görüleceği üzere, portföyler bazında sermaye yeterliliği için hesaplanan risk ağırlıkları, portföylerin ortalama TO'larını bir girdi olarak alıp onları bazı işlemlere tabi tutmaktadır. Bu işlemler aslında verilen ortalama TO'ları daha konservatif hale getirmek için yapılır. Yapılan dönüşüm Merton ile Vasicek modellerini baz alarak yapılmıştır³⁴. Bu hesaba göre portföydeki mevcut verilen ortalama TO'ya göre ve diğer korelasyon gibi parametrelere göre, portföydeki kaybın %99.9 ihtimalle hesaplanan değeri geçmeyeceği belirtilir. Beklenmeyen kayıplar için hesaplanan sermaye miktarı bu %99.9'luk güven aralığı için yapılmaktadır. Diğer bir deyişle %0.01'lik bir ihtimalle yaşanabilecek kaybın bu miktarı geçmesi beklenir. Çeşitli TO oranlarıyla, farklı varlık gruplarının diğer parametreler ile de olan kombinasyonları sonucu hesaplanan risk ağırlıkları Ek 1'de görülebilir.

³⁴ Vasicek, O. (2002) The Distribution of Loan portfolio value risk, Vol. 15, No. 3, ss. 26-32.

1.3. Basel Uzlaşıları

Tarihte yaşanan diğer krizlerin ve en son 2008 yılındaki küresel finansal krizin finansal sistem unsurlarına ve bütün dünyaya öğretmiş olduğu şey, risk fonksiyonların yetersizliğinin bir an önce giderilmesi olmuştur³⁵. Öyle ki herhangi bir risk analizi yapılmadan verilen kararlar bankaların ve böylelikle bankalara bağlı diğer unsurların zararına olmuş olup özellikle kredi riski alanında bankalar için belirli kurallar getirilmesi kaçınılmaz olmuştur. BCBS tarafından finansal sistemi korumak adına BASEL yönergeleri çıkartılmıştır.

1.3.1. Basel 1

BCBS tarafından yayınlanan BASEL uzlaşılarının ilki olan Basel 1 yönergesi 1988 yılında çıkartılmıştır. Asıl odak noktası sermaye yeterliliği olan uzlaşa da bankaların olası bir krizde sağlam durmalarının hedeflenmesi adına ilk defa bir sermaye yeterliliği oranı belirlenmiştir. Bu belirlenen sermaye yeterlilik oranı dünyada bankacılık sistemini ortak bir denetleme ölçütü belirleme altında attıkları ilk adım olmuştur. Öyle ki 100 den fazla ülkenin bankacılık kurumları belirlenen kuralların uyumuna ilişkin atacağı sermaye düzenlemeleri adımlarını bu uzlaşaya dayandırmışlardır. Bu kurala göre uluslararası alanda faaliyet gösteren bankaların sahip oldukları Risk Ağırlıklı Varlık (RVA) miktarına göre en az %8’lik bir sermaye ayırmaları kararlaştırılmıştır. Buna göre olası bir geri ödeme alamama durumunda bankaların olabilecek en az seviyede etkilenip, finansal sistemin bütününe tehlikeye atmayacak bir yapı oluşturacak kadar sermaye ayırmaları beklenmektedir.³⁶

Basel 1 ile getirilen bir başka konu ise bankalara ait varlık sınıflarının risk ağırlıklarına göre sınıflandırılmalarıdır. Bu kurala göre bir bankanın varlıkları %0, %10, %20, %50 ve %100 olmak üzere risklerine göre sınıflandırılacaktır. Bu değerlere göre, bankaların kredi verdikleri portföylere göre verdikleri miktarların risk ağırlıkları

³⁵ Balthazar L. (2006) Basel 1 to Basel 3. In: Basel 1 to Basel 3: The Integration of State-of-the-Art Risk Modeling in Banking Regulation. Finance and Capital Markets Series. Palgrave Macmillan, London. ss. 87-92.

³⁶ A.e. Balthazar.

ile çarpımı kadar RAV hesaplarlar. Daha sonra ise RAV değerlerini kullanarak sermaye yeterlilik oranını sağlayacak şekilde bir sermaye ayırırlar.³⁷

Görüleceği üzere oldukça basit kurallardan oluşan ilk Basel düzenlemesi riskleri yeterince sınıflandıramaz niteliktedir. Belirli 5 risk grubunun dikkate alındığı düzenleme gerçekte karşılaşılabilecek risklerin birçoğunu ayırtıramaz niteliktedir. Aynı zamanda müşterilerin geri ödeyememe risklerinin de hesaba katılmadığı bu kurallar da kredinin vadesi de dikkate alınmamaktadır. Bu tip eksikliklerin bulunduğu oldukça basit olan bu yaklaşımın yetersiz olduğu 1990 yıllarında Basel 1 ile belirlenen sermaye yeterlilik oranına uyan bankalarda yaşanan iflasların gerçekleşmesiyle gün yüzüne çıkmaktadır. Her ne kadar oldukça basit ve yetersiz olsa da finansal sistemin güçlenmesi adına küresel çapta atılan ilk adım olarak kabul edilen Basel 1 kuralları daha sonrasında yerini Basel 2'ye bırakmaktadır.

1.3.2. Basel 2

Oldukça basit bir yapıda olan ve bankalara coğrafya, risk, sektör gibi ayrımlar olmaksızın tek bir düzende bir değerlendirme bakış açısı veren Basel 1 kurallarına ek olarak 2004 yılında BCBS tarafından Basel 2 kuralları yayımlanmıştır. Basel 2 genelgesi sermaye ayrımı ve kredi riski konularında 3 sütun halinde getirdiği kurallar ile Basel sütunlarının ortaya çıktığı ilk Basel yönergesi olmaktadır. Piyasa disiplini, sermaye ayrımı gibi temel noktalar ile Basel 1'e göre çok daha komplike ve özelleştirilmiş kurallara sahip olan Basel 2 yönergeleri bankaların sermaye yapılarını ve küresel finans sistemini daha da güçlendirmeyi amaçlamaktadır. Buna göre Basel 1'in özellikleri ve yapısı gereği sermayenin yalnızca kredi riski unsurları ile ilişkilendirilmesi, kredi derecelerinin aynı risk ağırlığı katsayılarını alabilmesi, OECD ülkelerinin ayrılması, portföy içerisindeki çeşitlendirilmenin dikkate alınmaması, tüm bankaların tek bir yöntem ile risk parametrelerini hesaplamaları gibi eksikler doğurması sonucunda Basel 2 ile getirilen yenilikler ile bu eksikliklerin giderilmesi hedeflenmiştir. İlk defa Basel 2 ile ortaya çıkan Basel sütunları şu şekildedir³⁸.

³⁷ A.e. Balthazar.

³⁸ BABUŞÇU, Ş., (1997), "Bankalarda Risk Derecelendirmesi (Rating) ve Türk Bankacılık Sektörü'ne Uygulanması", SPK Yayınları, Sayı:4.

- Birinci Sütun: Asgari Sermaye Yükümlülükleri
- İkinci Sütun: Denetim Otoritesinin Gözden Geçirilmesi
- Üçüncü Sütun: Piyasa Disiplini

Buna göre Basel yönergeleri birinci sütuna bakacak olunursa, Basel 1’de ortaya çıkan, hesaplanması gereken sermaye yeterlilik rasyosu için %8’lik oran bozulmamaktadır. Aynı şekilde öz sermayenin tanımı da aynı kalmaktadır. Öte yandan Basel 1’den farklı olarak toplam risk ağırlıklı varlık hesaplamalarına kredi riski haricinde diğer finansal riskler de dahil edilmektedir. Bu riskler piyasa riskleri ve operasyonel risk olarak belirlenmiştir. Bir diğer önemli husus ise Basel 2 yönergeleri ile birlikte bankalar risk ağırlıklı varlıklarını tek bir kat sayı ile yapmak durumunda kalmayacaklardır. Basel 2 yönergeleri ile birlikte artık her banka kendi içsel derecelendirme modelleri (IDD Modelleri) ile belirli kurallar dahilinde kendi hesaplamalarını yapabiliyor, kendi modellerini oluşturabileceklerdir. Bankaların kendi iç modelleriyle hesaplayabileceği³⁹ parametrelerin başında Temerrüt Oranı (TO), Temerrüt Halinde Kayıp (THK) ve Temerrüte Düşen Tutar (TDT) değerleri gelmektedir. Araştırmaya konu olan İçsel Derecelendirme Temerrüt Oranı modellerinin de çıkış noktası finansal sistemi güçlendirmek için ortaya çıkan Basel 2 kuralları olmuştur. Sonuç olarak bankalar sermaye hesaplamalarında kullanmaları gereken değerleri artık tek bir sabit katsayı olarak değil de kendi modelleriyle hesapladıkları değerlerden kullanacaklardır.

Basel 2’nin ikinci sütununda ise bankaların yıllık veya dönemsel olarak sermayelerinin yeterli seviyede olup olmadıklarını test etmeleri gerekliliğini açıklanmaktadır⁴⁰. Buna göre bankalar yalnızca kredi riski, piyasa riski veya operasyonel risk değil diğer finansal olmayan riskleri de hesaba katarak bir değerlendirmede bulunmalıdırlar. Bu risklere örnek vermek gerekilirse, saygınlık riski, konsantrasyon riski, siber risk gibi risk türleri örnek verilebilir. Bankalar her yıl

³⁹ YİLDİRİM, O. (2015, Şubat). Türk Bankacılık sisteminde basel kriterleri. Finans Politik & Ekonomik Yorumlar 2015 Cilt: 52 Sayı: 609 ss. 9-20.

⁴⁰ Bankacılık Düzenleme ve Denetleme Kurumu, 10 Soruda Yeni Basel Sermaye Uzlaşısı (Basel II), (Çevrimiçi), Ekim 2009.

düzenli olarak İçsel Sermaye Yeterliliği Değerlendirme Süreci (ICAAP) adı altında üst yönetimin de dahil olduğu, bankanın mevcut durumunun yanı sıra çeşitli kötü durum senaryolarında da sermayenin yeterli olup olamayacağının testini yaparlar⁴¹. Bu kötü durum senaryoları bankaların kendileri tarafından hazırlanabileceği gibi, denetleyici kurumlar tarafından da bankalara sunulabilir.

Üçüncü sütun olan piyasa disiplini sütunu ise bankalara kendi içsel prosedürleri, işlemleri hakkında şeffaf olmaları yönünde kurallar içermektedir. Böylelikle piyasanın disiplini – düzeni kontrol edilebilmektedir.⁴²

1.3.3. Basel 3

2008 finansal krizinin ardından, o zamanda mevcutta yürürlükte olan Basel 2 kurallarının yetersizliği de kriz ile birlikte gün yüzünde çıkmıştır. Amacı finansal sistemin istikrarını sağlamak olan kurallar topluluğunun uygulanmasının 2 yıl ardından küresel çapta bir finansal krizin bütün dünyayı ve finansal sistemi etkisi altına alması, mevcuttaki kuralların aslında ne kadar amacına hizmet edemediğini göstermekteydi. Bu sebeple kriz sonrasında BCBS tarafından Basel 3 yönergesi çıkartılmıştır. Basel 3'ün konu aldığı mevcut yetersizlikler ve bazı temel iyileştirmeler şöyledir⁴³:

- Kriz durumlarında veya kötüleşen senaryolarda ani bir şekilde düşüş gösterebilecek olan sermaye tamponlarının artırılması ve daha sağlam bir yapı alması,
- Sermayenin tanımı ile birlikte kalitesinin artması,

⁴¹ Draper, T. (2014). Regulation of capital adequacy in Western European banking through the Internal Capital Adequacy Assessment Process (ICAAP) & the Supervisory Review & Evaluation Process (Srep). CRIS - Bulletin of the Centre for Research and Interdisciplinary Study, 2014(2) ss. 29-49.

⁴² A.e. BDDK.

⁴³ KÜLAHİ, E. A. (n.d.). TÜRKİYE'DE BASEL İ, İİ ve İİİ KURALLARINA UYUM SÜRECİ. 2013, Cilt 10, Sayı 40, ss. 185 – 200.

- Mevcut likidite ve sermaye oranlarının yetersizliği sebebiyle yeni oranların çıkartılması,
- Stresli kriz durumlarında dahi yeterli sermayeye sahip olabilmeyi sağlama.

Bu amaçlarda sermaye tanımını güçlendirmek için atılan en önemli adım sermaye tanımının değiştirilmesidir. Bu sayede niteliği ve niceliği daha da kuvvetlenmiş bir sermaye yapısı ortaya çıkmaktadır.

Basel 3 ile gelen yeniliklere aşağıda daha detaylıca değinilmektedir.⁴⁴

- Öz kaynaklar

Sermaye yeterlilik rasyosunun sağlanmasındaki amaç risk ağırlıklı varlıklara oranla bir sermaye ayrılmasının sağlanmasıdır. Buradaki önemli bir konu da bu sermayenin ne olduğudur ve nasıl tanımlandığıdır. Basel 3 ile birlikte öz kaynağın tanımlanması da değişmiş olup bankaların ayırmaları gereken sermaye miktarları da değişiklik göstermiştir.

Bankalarda sermaye kavramı, sermayenin kalitesine ve kaynağına göre sınıflara ayrılmıştır. Buna göre birinci sınıf sermaye denilen kavram bankanın pay sahiplerinin öz koymuş olduğu öz kaynak ve kazançlardan oluşuyor olup bir bankanın birincil fonlama kaynağıdır. Birinci tip sermaye bankanın mali durumunun ve sağlığının ne durumda olduğunun bir göstergesidir. İkinci sınıf sermaye ise sermaye araçları veya vadeli borçları kapsadığı gibi açıklanmamış olan rezervleri de içermektedir. Buna göre İkinci sınıf sermaye birinci sınıf sermayeye göre hesaplanması ve likidite azlığından ötürü daha az güvenilir kabul edilmektedir.

Buna göre Basel 3 ile birlikte bir bankanın sahip olduğu birinci sınıf ve ikinci sınıf varlıklar en az %10.5 olmak üzere şartlandırılmışlardır. Bu oran bir önceki Basel 2 yönergesinde %8 olarak belirtilmekteydi. Buna ek olarak Üçüncü sınıf sermaye olarak nitelendirilen ve daha çeşitli borçlardan oluşan sermaye sınıfı Basel 3 ile birlikte kaldırılmıştır.⁴⁵

⁴⁴ Arslan, İ. (2007). BASEL KRİTERLERİ VE TÜRK BANKACILIK SEKTÖRÜNE ETKİLERİ . Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi , (18) , ss. 49-66 .

⁴⁵ A.e. Balthazar.

- Sermaye Oranları

Basel 3 ile birlikte bankaların tutmaları gereken sermaye miktarlarının tanımına ek olarak tutmaları gereken oranlar da değişmiştir. Buna göre bir bankanın toplam risk ağırlıklı varlıkları için çekirdek sermayesinden ayırması gereken sermaye miktarı %4.5 olarak belirlenmiştir. Bu miktar Basel 2’de %2 olarak bulunmaktaydı, bu oranın artırılması bankanın yaşayacağı olası bir olumsuz durumda en kaliteli bir diğer deyişle likit olan fonun miktarını artırmak anlamına gelmektedir.

Bu değişikliğe ek olarak bir bankanın sahip olması gereken Birinci sınıf sermaye oranı %6 olarak belirlenmiş yine aynı şekilde toplam sağlanması gereken genel sermaye oranı ise %8 olarak kabul edilmiştir. Basel 2’ye ek olarak bu bahsedilen %8’lik sermaye oranının üstüne bankaların %2.5’a kadar bir tampon durumu görecektir. Bu tampon oran da hesaba katılacak olunursa toplam tutulması gereken miktar %10.5 olarak belirlenmektedir.

- Kaldıraç Oranı

Basel 3 ile birlikte gelen yeniliklerden birisi de kaldıraç oranıdır. Bankalar sermaye oranlarına yönelik gereksinimleri yerine getirirken bazı durumlarda çokça kaldıraç kullanırlar. Bu durum onları daha riskli bir pozisyona getirmekle birlikte aslında gerçek olmayan sahte iyi bir görünüm almalarına da sebebiyet vermektedir. Bu sebeple Basel 2’de eksik kalan bu gereksinim Basel 3 ile birlikte Kaldıraç oranı gereksinimi ile kontrol altına alınmaya çalışılmıştır. Basel 3 ile birlikte gelen kaldıraç oranı hesaplaması aşağıdaki denklemde görülebilmektedir.

$$\frac{(Ana Sermaye)}{(Aktifler + Blanço Dışı Kalemler)}$$

Buna göre belirtilen oran en az %3 olmalıdır.

- Likidite Oranları

Basel 3 ile gelen yeni oranlardan bir diğeri de likidite oranlarıdır. Likidite bir varlığın ne kadar hızlı ve ne kadar değer kaybetmeden nakde çevrilebileceğini gösterir. Buna göre olası kötü senaryolarda bankaların hızlıca ve değer kaybetmeden zararı

karşılacak varlıklara sahip olmaları beklenir. Bu sebeple Basel 3’de Likidite karşılama oranı ve Net istikrarlı fonlama oranı olmak üzere iki farklı likidite oranı getirilmiştir. Likidite karşılama oranına göre bankalar en az 30 günlük yüksek derece likit varlıklara sahip olmaları gerekir⁴⁶. Bir varlığın ne kadar likit özellikte olduğu denetleyici kurumların yönergelerine göre belirlenmektedir. Örnek vermek gerekirse BDDK’nın yayınladığı Bankaların likidite karşılama oranı hesaplamasına ilişkin yönetmelikte seçilen bazı varlıkların ne kadar likit olduklarına dair oran Ek 2’de gösterilmektedir. Likidite karşılama oranı aşağıda gösterilen denklem ile hesaplanmaktadır.

$$\text{Likidite Karşılama Oranı} = \frac{\text{Yüksek Kaliteli Likit Varlıklar Stoku}}{\text{Toplam Net Nakit Çıkışları}}$$

Net sabit fonlama oranı ise bankaların varlıkları ile bilanço dışı işlemlerinin yapılarına göre düzenli ve sabit bir finansal profil oluşturmayı hedefler⁴⁷. Buna göre net sabit fonlama oranı formülü mevcuttaki sabit fonların gereken sabit fonlara bölünmesiyle bulunur. Bu oranın %100’den büyük olması gerekmektedir⁴⁸. Bir diğer deyişle bir başka deyişle mevcuttaki miktar en azından gereken miktar kadar olmalıdır.

1.3.4. Basel 4

BCBS tarafından 2017 yılında tamamlanmış olan yönergenin Ocak 2022 yılında uygulamaya girmesi planlanmaktadır. Henüz zaman olmasına karşın bankalar kendilerini yeni çıkacak olan ve birçok noktada gerek ayrılan sermayeye gerek ise risk ağırlıklı varlık hesabına etkiye bulunacak olan bu yeni yönergeye karşın hazırlıklı hale getirmeye başlamışlardır⁴⁹. Bu açıdan Basel 4’ün etkileri şimdiden bankalar üzerinde görülebilmektedir.

⁴⁶ BIS, "Revisions To Leverage Ratio Disclosure Requirements". (Çevrimiçi) 2019.

⁴⁷ BIS, "Basel III: The Net Stable Funding Ratio". (Çevrimiçi) 2014.

⁴⁸ BIS, "Basel III: The Liquidity Coverage Ratio And Liquidity Risk Monitoring Tools". (Çevrimiçi). 2013.

⁴⁹ Schenider S, Basel “IV”: What’s next for banks? Implications of intermediate results of new regulatory rules for European banks. Basel “IV”: What’s next for banks? (Çevrimiçi) (2017, Nisan).

Basel 4 kuralları, Basel 3 kurallarının aksine Sermaye yeterlilik rasyonusun pay kısmından ziyade bir diğer deyişle sermaye tanımlamalarından ziyade daha çok payda kısmına yönelik deęişiklikler ve yenilikler ile gelmektedir⁵⁰. Sermaye yeterlilik rasyosunun payda kısmında bulunan Risk ağırlıklı varlık hesaplamalarında meydana gelecek deęişiklikler ile birlikte bankaların ayırmaları gerekecek olan sermaye miktarları da deęişmektedir.

Basel 4 ile birlikte gelen en önemli yeniliklerden birisi de çıktı kısıtlamasının getirilmesidir. Çıktı kısıtlaması düzenleyici kuruluşlar tarafından kontrol edilen, içsel derecelendirme yöntemi ile risk ağırlıklı varlık hesaplayan bankalar ile standart yöntem ile risk ağırlıklı varlık hesaplayan bankalar arasındaki farkın çok olmamasını amaçlar ve içsel derecelendirme modelleri kullanan bankalara hesapladıkları sermaye miktarının en az standart yaklaşım ile hesaplananın belirli bir yüzdesi kadar olmasını gerektirmektedir. Basel 4’de ise bu yüzde tam uygulamaya geçilinceye kadar kademeli olarak artmak ile birlikte tam uygulandığında %72.5 olarak belirlenecektir. Bir başka deyişle içsel derecelendirme modeliyle RAV hesaplayan bankalar standart yöntem ile ayırmaları gereken sermaye miktarının en az %72.5 ini ayırmak durumundadırlar. Bu kısıtlama çok daha az riskli bir portföye sahip olan bankaların ayırmaları gereken sermaye miktarlarını artırmaları ile sonuçlanmaktadır. Çünkü risksiz bir portföye sahip olan ülkelerde hazır kullanılan varlık grubu katsayıları portföyün olması gereken riskten fazla olabilir ve bu durum da bankaları fazladan sermaye hesaplama durumuna götürebilmektedir.⁵¹

Basel 4 ile kredi riski açısından gelecek olan en köklü deęişiklik çıktı kısıtlaması olsa da Basel 4 daha farklı uygulamalar da beraberinde getirmiştir. Bu deęişiklikler⁵²:

- Standart yaklaşım için katsayıların deęiřmesi

⁵⁰ Deloitte United States, Basel III to "Basel İV": What changed?: Deloitte SEA: Risk Advisory. (Çevrimiçi) (2018).

⁵¹ Akkizidis, I., & Kalyvas, L. (2018). Output Floor, leverage ratio, and other regulatory requirements. Final Basel III Modelling, (Basılı) ss. 289–310.

⁵² A.e. Akkizidis & Kalyvas.

- Büyük kurumsal firmalarda bankaların içsel derecelendirme modelleri ile parametre hesabı yapmasına engel getirilmesi
- İleri İçsel Derecelendirme (A-IRB) ile parametre hesabına kısıtlama getirilmesi.

şeklinde sıralanabilir.

Standart yaklaşım ile sermaye hesaplama yoluna giden bankalar risk ağırlıklı varlıklarını her bir varlık sınıfına göre belirlenen risk ağırlıkları ile hesaplayıp ona göre sermaye rasyosunu tutturmak amaçlı bir sermaye ayırımı yapmaktadırlar. Bu hazır risk ağırlığı kat sayılarının değişmesi risk ağırlıklı varlık miktarlarını değiştireceği gibi sermaye üzerinde de artırıcı veya azaltıcı bir etki bırakmaktadır.⁵³

Büyük kurumsal firmalarda temerrüt az görülen bir olaydır. Bu sebeple istatistiksel modeller kurulurken az sayıda temerrüt olduğu için bu veriden istatistiksel bir çıkarım yapmak oldukça zor olacaktır. Bu sebeple temerrüt verisinin az olduğu bu portföylerde istatistiksel modellerden ziyade uzman görüşlerinin ağırlıklı olduğu modeller kullanmak daha doğru olacağı düşünüldüğünden Basel 4 ile birlikte artık büyük kurumsal firmalar için içsel derecelendirme modelleri kullanılmamasına karar verilmiştir.⁵⁴

1.4. Denetleyici Kurumlar Ve Uygulatici Merciler

Finansal sistemin istikrarını ve bir daha küresel boyutta bir ekonomik kriz yaşanmaması için alınması anlaşılan ve planlanan bir dizi kuralların olduğu Basel yönergelerinden önceki bölümde bahsedilmiştir. Bu yönergeler Avrupa Birliği yasalarında tek kural kitabı adı altında kredi riski konusu için Sermaye Gereklilikleri Düzenlemeleri (CRR) ve Sermaye Gereksinimleri Direktifleri (CRD) isimleri ile yer bulmaktadır. Bu kuralların bankalar tarafından birebir nasıl uygulamaya alınacağı ve düzgün bir şekilde uygulamaya alınıp alınmadığını kontrol etme amaçlı Avrupa Bankacılık Otoritesi (EBA) ve Avrupa Merkez Bankası (ECB) belirli çalışmalar

⁵³ Gatzert, N., Martin, M. (2012). Quantifying credit and market risk under solvency II: Standard approach versus internal model. SSRN Electronic Journal, 51(3), ss.649–666.

⁵⁴ A.e. Gatzert.

yürütmektedir. Bu kurumlar ile onların görevleri ve bu finansal sistemin istikrarı hedefi doğrultusunda üstlendiği sorumluluklar sıradaki bölümde anlatılmaktadır.

1.4.1. Avrupa Bankacılık Otoritesi (EBA)

Bağımsız bir Avrupa Birliği otoritesi olan Avrupa Bankacılık Otoritesi (EBA), Ocak 2011 yılında Avrupa Parlamentosunun 1093/2010 numaralı düzenlemesi ile kurulmuştur. Avrupa Birliği içerisinde bankalar arasında etkili ve istikrarlı bir denetim görevi üstlenen EBA bu sayede Avrupa birliği içerisindeki finansal istikrarı sağlamayı amaçlamaktadır.

1.4.1.1. Amacı ve Görevleri

EBA çıkarttığı bağlayıcı teknik standartlar ve yönergeler ile Basel kurallarının yer aldığı Avrupa Birliği yasasındaki CRR ve CRD’lerde bahsedilen konuları bankaların nasıl uygulamaları gerektiğini açıklamaktadır⁵⁵. Kısa bir ifadeyle, EBA nispeten kısa ve genel ifadelerle yasada bulunan Basel kurallarını daha detaylıca ve pratikte nasıl uygulanacağı konusunda açıklamalarla bankalara yönergeler halinde sunmaktadır. Bunların yanı sıra EBA’nın görevlerine bakıldığında:

- Ulusal otoriteler tarafından Avrupa Birliği yasalarında bir yanlış uygulama olup olmadığını incelemek,
- Acil durumlar finansal kurumlar için kararlar vermek,
- Avrupa Parlamentosunda bağımsız danışman olarak görev almak,
- Çelişen sınırlar arası durumlarda aracı görevi üstlenmek

olarak sıralanabilir. Bu görevlerini gerçekleştirebilmek için ise bağlayıcı teknik standartlar, yönergeler, tavsiye yazıları, görüşler ve anlık veya düzenli raporlar yayınlamaktadır. Bağlayıcı teknik standartların uygulanmaları yasal olarak zorunludur ve takip edilmektedir ve bütün üye ülkelerde uygulanmaları gerekmektedir⁵⁶.

⁵⁵ European Banking Authority. (n.d.). About Us. (Çevrimiçi), Mart 28, 2021.

⁵⁶ A.e. European Banking Authority.

1.4.1.2. Baęlayıcı Teknik Standartlar ve Yönergeler

EBA tarafından ıkartılan, kredi riskin belirli aralarında düzen ve uyumu saęlamayı amaçlayan baęlayıcı teknik standartlar ve yönergelerden bazıları ařaęıdaki gibi sıralanabilir⁵⁷:

- TO ve THK Parametreleri Hesaplaması Yönergesi
- IDD Modelleme Uygulamaları Raporu
- IDD Deęerlendirme Metodolojileri Yönergesi
- Temerrüt Tanımı Yönergesi
- Kriz Döneminde THK Parametresi Hesaplama Yönergesi
- Ekonomik Kriz Belirleme Yönergesi
- Kredi Verme ve Takip Etme Yönergesi

1.4.2. Avrupa Merkez Bankası (ECB)

Avrupa Merkez Bankası (ECB) Avrupa gölgesi içinde bulunan 19 ülkeyi kapsayan para politikalarını yönetmekle görevli bir kurumdur. Banka aynı zamanda baęlı olan ülkelerde bulunan bankalardaki Basel kuralları çerçevesinde uygulanan İçsel Derecelendirme Modelleri kurallarının doęru uygulanıp uygulanmadığını da denetlemektedir.

Avrupa Merkez Bankasının başlıca görevleri ařaęıdaki gibidir⁵⁸.

- Enflasyonu kontrol altında tutmak,
- Bankacılık sisteminin güvenlięine katkıda bulunmak,
- Euro biriminden para basmak – paraların tasarımıını dizayn etmek,
- Finansal alt yapının düzgün alıřtıęından emin olmak,
- Finansal istikrarın korunmasını saęlamak.

ECB'nin görevleri arasında yukarıdaki listede yer alan bankacılık sisteminin güvenlięinin saęlanmasına katkıda bulunma ve finansal istikrarın korunmasını saęlamak maddeleri, ECB'nin Basel kurallarıyla doęrudan alakalı olduęu noktaların başında gelmektedir. Nitekim bu iki kural, bankacılık sisteminin güvenlięi ve finansal

⁵⁷ European Banking Authority. (2021, Mayıs 5). EBA at a glance. (evrimii), Mart 28, 2021.

⁵⁸ European Central Bank, E. C. B. (2021, Aęustos 25). About Us. (evrimii) Mart 28, 2021.

istikrarı sağlamak, temel amacı finansal sistemin güvenliğini ve istikrarını sağlamak olan Basel kurallarıyla doğrudan örtüşmektedir. ECB bankalara yaptığı düzenli denetlemeler ile bankaların ne derecede Basel kurallarına uyum sağladıklarını kontrol etmektedir. ECB'nin bu noktadaki etkisi doğrudan bankaların geliştirdikleri istatistiksel modellerin kendi kurum içinde bağımsız bir validasyon birimi tarafından valide edilmesinden sonra bir kere daha modellerin kurulumunu ve validasyon işlemini standartlara uygun olarak yapılıp yapılmadığını kontrol etmeleriyle sağlanır ECB gerek yayınladığı dokümanlarla olsun gerek ise yaptığı denetlemelerle olsun Basel kurallarına ve onun EBA tarafından yayınlanan uygulamalarına uyulup uyulmadığını denetlemekle görevlidir.⁵⁹

⁵⁹ A.e. European Central Bank.

İKİNCİ BÖLÜM

İÇSEL DERECELENDİRME MODELLERİ GEREKSİNİMLERİ VE MAKİNE ÖĞRENMESİ ALGORİTMALARI

İçsel derecelendirme modelleri geliştirilirken uyulması gereken kurallar ve takip edilmesi gereken adımlar EBA'nın yayınladığı yönergeler ile açıklanmaktadır. Bölümün devamında IDD modelleri geliştirilirken takip edilmesi gereken yönergeler ve daha sonrasında ise lojistik regresyon modeli ile alternatif makine öğrenmesi modelleri nitel olarak analiz edilecektir.

2.1. Eba Yönergeleri Analizi

Önceki bölümde bahsedilen 2013 yılında çıkartılan Avrupa Birliği 575 numaralı yasasındaki Basel kurallarını içeren CRR⁶⁰ ve CRD'lerdeki maddelerin nasıl uygulanacağını anlatan EBA yönergelerinin açıklamaları ve bu yönergelerin bankaların modellerine olan etkileri sıradaki bölümde anlatılacaktır. Basel kurallarının EBA yönergeleriyle uygulanmaları hesaplanan parametrelere önemli etkileri olmaktadır, sıradaki bölümde temel EBA yönergelerine değinilecek olup EBA yönergeleri burada anlatılacaklar ile sınırlı değildir. Sıradaki bölümde anlatılacak olan kurallar ve yönergeler bankaların IDD modellerine önemli etkileri olmasına karşın çalışmanın sonunda geliştirilecek olan makine öğrenmesi modellerinde bu yönergeler basitleştirme gereği tamamen uygulanmayacaktır. Çalışmanın asıl amacı değişik makine öğrenmesi yöntemlerini karşılaştırmak olup, Basel yönergeleri ile gelen bu değişikliklerin de etkileri olabildiğince yansıtılmaya çalışılacak olup çalışmanın temel amacından da sapılamamak hedeflenmektedir. EBA yönergelerinin IDD modellerine olan etkisi ve etkisinden öte modelleri tanımlamaları kesinlikle göz ardı edilmemelidir ve çalışmada bahsedilmesi gerekli olduğu düşünülmektedir.

⁶⁰ European Union. (2013, Haziran). Prudential requirements for credit institutions and investment firms and amending Regulation (EU) No 648/2012.

2.1.1. Temerrüt Tanımı Yönergesi

Kredi riski modelleri geçmiş veriyi kullanıp geleceği tahmin etmeyi amaçlayan istatistiksel makine öğrenmesi modelleridir. Makine öğrenmesi yöntemleri bağımlı değişkenin bulunup bulunmamasına göre gözetmeli ve gözetimsiz öğrenme olarak ikiye ayrılır. Gözetimli öğrenmede model kendisine gösterilen / etiketlenen sonuç değerleri bir diğer deyişle bağımlı değişkenler ile bağımsız değişkenler arasındaki ilişkiyi kurmaya yönelik hareket eder⁶¹. Gözetimsiz öğrenmede ise model veri setindeki çeşitli desenlerden yola çıkarak belirli karakter özelliklerini kullanarak veri setini gruplar ve kategorilere ayırır. Daha sonra bu kategorizasyonu öğrenerek bundan sonra gelecek yeni verilere uygular. Buradan da anlaşılacağı üzere bağımlı değişken gözetimli öğrenme modelleri için oldukça önemli bir kavramdır ve algoritmanın öğrenilmesine bir diğer deyişle modelin kurulmasına rehberlik eder niteliktedir. Bir diğer deyişle modelimiz her ne olursa olsun bağımlı değişkenin nasıl tanımlandığı modelin kendisine ve doğal olarak çıktısına etki eden en önemli kavramdır. Kredi riski Temerrüt oranı modellerinde kullandığımız tarihsel verideki bağımlı değişken ise müşterinin temerrüte düşüp düşmediğidir. Müşteri buna göre 1 veya 0 olarak etiketlenir ve model müşterinin diğer bağımsız değişkenlerini kullanarak onların bağımlı değişkene olan etkisini algoritmanın yapısına göre öğrenir bundan sonra yeni gelecek müşterilere bu öğrendiği algoritmayı uygulayıp geleceğe yönelik bir tahmin yapar. Buna gözetimli makine öğrenmesi yoluyla geleceği tahminleme denir. Temerrüt tanımının model geliştirilirken kullanılan veri setine etkisini görmek amacıyla temsili bir örnek vermek gerekirse, Tablo 1 de EBA ‘Temerrüt Tanımı Uygulamaları’ yönergeleri kapsamına girmeden yalnızca 90 günlük gecikme gün sayısından doğan temerrüt tanımı ile işaretlenmiş ve belirlenmiş bağımlı ‘Temerrüt’ değişkeni görülmektedir. Temerrüt değişkeni ile faiz, amortisman, vergi öncesi kar (FAVÖK) değişkeni kullanılarak temsili bir model kurulmaktadır.

⁶¹ Amidi, A. (n.d.). Gözetimli öğrenme El Kitabı. CS 229 - Gözetimli Öğrenme El Kitabı.(Çevrimiçi) Ağustos 28, 2021.

Tablo 1 : Temerrüt Tanımı Etkisi Örneği - Öncesi

Öncesi	
FAVÖK	Temerrüt
10	0
12	1
8	1
20	0
28	1
41	0
33	0
16	0

Aynı şekilde, EBA yönergesi sonrası bölümün kalanında bahsedilen yeni temerrüt tanımları ile belirlenen temerrüt etiketi değişimi sonrası Tablo 2 ‘deki gibi veri seti güncellenmiştir.

Tablo 2 : Temerrüt Tanımı Etkisi Örneği - Sonrası

Sonrası	
FAVÖK	Temerrüt
10	1
12	1
8	1
20	0
28	1
41	0
33	0
16	1

Temerrüt tanımı yönergesi sonucu değişen veri seti ile kurulan modelde FAVÖK değişkeninin modele etkisi ve yorumlanması da değişmektedir. Örnekte de görülebileceği üzere, ilk tabloya kıyasla ikinci tabloda düşük FAVÖK değerlerinin temerrüte daha çok etkide bulunduğu görülmektedir. Bu değişimden yola çıkarak güncellenmiş temerrüt tanımı ile kurulan veri setinden kurulan model FAVÖK değişkenine daha çok önem yüklemektedir ve FAVÖK değişkeninin modeldeki denklemden değerleri daha farklı olacaktır. Bu örnek de temerrüt tanımının bankaların kredi riski modellerine olan doğrudan etkisini ve ne kadar önemli olduğunu gösterir niteliktedir.

Temerrüt tanımı, bankaların müşterilerini hangi şartlar altında temerrüte düşmüş olarak kabul edeceğini belirten bir kavramdır. Kredi riski modellerinde bağımlı

değişken görevi gören bu kavram, 2013 yılı Avrupa Birliği düzenlemeleri 575 numaralı paragrafa itafen 2016 yılında EBA tarafından çıkartılan, Temerrüt Tanımı Uygulamaları Yönergesi⁶² adı altında bankaların IDD yöntemi kullanmaları halinde temerrüt tanımı için hangi gereksinimlere sahip oldukları açıklanmıştır. Bu yönergeye göre bankaların bir müşteriyi temerrüt olarak kategorilendirilmesi için 2 temel kriter vardır⁶³.

- 1- Gecikme günü kriteri
- 2- Ödememeye meyillilik kriteri

Bu temel kriterler kendi içlerinde çeşitli alt kategorilere ayrılmaktadır. Gecikme günü kriteri, müşterinin yükümlü olduğu miktarı planlanan ödeme süresi içinde ödeyememesinden kaynaklanan temerrüte düşmelerin kapsamından bahsetmektedir. Bir diğer deyişle gerçekleşmiş olan, görülebilen olayları kapsar. Ödememeye meyillilik kriteri müşterinin henüz ilk kriterde belirtilen olaylardan temerrüte düşmüş olmamasına ek olarak, bankanın belirli alt kriterler ile müşterinin gelecekte yükümlü olduğu miktarı ödeyemeyeceğine kanaat getirmesiyle müşteri temerrüte düşmüş olarak kaydetmesiyle gerçekleşir. Bankanın hangi durumlarda müşteriyi ödeyemeyeceğine hüküm getirip temerrüt olarak kaydedeceği yine aynı yönerge içinde bahsedilmiştir. Yönergeye göre başlıca ödememeye meyillilik kriterleri şöyledir :⁶⁴

- Kredi yükümlülüklerinin satılması
- Yeniden Yapılandırmaya gidilmesi
- İflas durumu
- Belirli kredi riski eklemeleri

⁶² European Banking Authority. (n.d.). Final Report Guidelines on the application of the definition of default under Article 178 of Regulation (EU) No 575/2013. Ağustos 28, 2021.

⁶³ A.e. European Banking Authority.

⁶⁴ A.e. European Banking Authority.

2.1.1.1. Ödememeye Meyillilik Kriteri

CRR'ın 178'inci madde, 3'üncü bendi C fıkrası⁶⁵ gereği, kredi riski sonucunda yükümlülüklerin satılması sonrasında doğacak olan önemli miktardaki maddi zarar temerrüt olarak nitelendirilmektedir⁶⁶. Ancak burada dikkat edilmesi gereken konu yükümlülüklerin satılmasının sebebinin kredi riski sebebiyle mi olup yoksa likiditeyi artırmak gibi diğer şirket stratejisindeki değişikliklerden mi kaynaklandığının ayrımının yapılmasıdır. Bu durumda yükümlülüklerinin satılmasının nedeni ile birlikte satışın sonrasında oluşacak zararın da boyutu önemlidir. Kredi yükümlülüklerinin satılmasının sebebi kredi riski ile ilgili sebepler olduğu belirlenirse bu durumda ise bu satıştan ne kadar zarar edildiğine bakılmalıdır. Kredi yükümlülüklerinin satış fiyatı ile gerçek fiyatlarının arasındaki farkın bir eşik noktasını geçmesi halinde banka müşterisini temerrüte düşmüş olarak işaretleyebilir. Bu eşik noktası bankaların risk politikaları kapsamında kendi içlerinde belirlenebilir.⁶⁷

CRR 178. madde, 3. bent d fıkrası⁶⁸ gereği, kuvvetli derecede yeniden yapılandırmaya giren şirketler, bankalar tarafından ödememeye meyilli olarak kategorilendirilmelidir. Ana para, faiz veya diğer ücretlerdeki ödemelerin ertelenmesi veya uzun vadeler halinde yeniden ödeme planı oluşturulması ile mevcut ödeme planı değiştirilebilir. Burada dikkat edilmesi gereken konu, her türlü yeniden yapılandırmanın temerrüt sebebi sayılamayacağıdır. Mevcut ödeme planının belirli bir faiz oranı ile bugüne indirgenmesi ile sonradan oluşturulan ödeme planının nakit akımlarının aynı faiz oranı ile bugüne indirgenmesi ile ortaya çıkan iki farklı bugünkü değer arasındaki fark temerrüttü belirlemede kullanılır. n adet yıl için R miktarlardaki nakit akımlarıyla, belirli bir faiz oranını (i) kullanarak net bugünkü değer (NBD) hesabının nasıl yapılacağı aşağıdaki denklemde gösterilmiştir.

⁶⁵ A.e. European Union s. 112.

⁶⁶ A.e. European Banking Authority.

⁶⁷ Florian Manz, 2019. "Determinants of non-performing loans: What do we know? A systematic review and avenues for future research," Management Review Quarterly, Springer, vol. 69(4), ss.351-389.

⁶⁸ A.e. European Union s. 113.

$$NBD = \frac{R(1)}{(1+i)^1} + \frac{R(2)}{(1+i)^2} + \dots + \frac{R(n)}{(1+i)^n}$$

NBD: Net Bugünkü Değer

R(n) : n zamanında gerçekleşen nakit akışı

i : indirgeme için kullanılan faiz oranı

Bu farkın bankanın belirlediği belirli bir eşik değerini geçmesi bankanın müşteriye temerrüte düşmüş olarak etiketlemesiyle sonuçlanır. Bazı durumlarda bu iki farklı ödeme planından hesaplanan net bugünkü değer farklarının eşik değerini geçmediği durumlarda, bankalar yine de müşteriye temerrüt olarak işaretleyebilirler. Bu durumlar ödememeye meyillilik kriterlerinin diğer durumlarına da değinen eden büyük tek seferdeki toplu ödeme durumlarını, erken kapatma durumlarını veya birden çok seferdeki yeniden yapılandırma durumlarını kapsayabilmektedir. Bu gibi durumlarda bankalar fark eşik değerinin altında kalsa da temerrüt olarak belirleyebilmektedir.⁶⁹

CRR 178. madde, 3. bent e ve f fıkraları⁷⁰ gereği, bir şirketin iflasını ilan etmesi o şirketin ödememeye meyillilik kriterinden temerrüt olarak işaretlenmesini gerektirir. Burada şirketin henüz 90 günlük ödeme geciktirmesini beklemeden banka şirketi temerrüte düşmüş olarak kabul edebilmektedir⁷¹. Bu sayede bankalar iflas edip bir daha taahhüt edilen ödemeleri yapamayacağı şirketleri temerrüt olarak sınıflandırmak için gecikme gün sayılarının dolmalarını beklememektedirler.

CRR 178. madde 3. bent b fıkrası gereği, bir şirketin kredi kalitesindeki gözle görülür düşüş sonrasında uygulanan özel kredi riski eklemesi (SCRA), bankalar için temerrüt tanımlanabilir kriterler arasındadır. Hangi şartlardaki kredi riski eklemelerinin SCRA olarak tanımlanabileceği CRD 1. Madde 5. Bent a ve b fıkralarında belirtilmektedir. Buna göre mevcut muhasebe hesaplaması bakış açısında,

⁶⁹ A.e. EBA.

⁷⁰ A.e. European Union s. 113.

⁷¹ A.e. Manz.

finansal enstrümanların makul değerlerinde gerçekleşen kar ve zararların kredi riski tarafından sorumlu olan kısmı ile geçmişten gelen veya şundaki belirli bir riskten kaynaklanan zararlar kredi kalitesinde belirgin düşüş olarak nitelendirilip, bankalar tarafından ödememeye meyillilik kriteri sayılmalıdır. Öte yandan birikmiş olan ancak muhasebeleştirilmemiş olan zararlar CRD 1. Madde 5.bent c fıkrası gereği SCRA olarak görülmemelidirler. Bu tarz SCRA'lar, zararın gerçekleşmiş olduğunu ancak şirket tarafından hissedilmemiş veya yansıtılmamış olduğunu belirttiğinden kaybı kredi kalitesinin düşüşü ile yorumlayıp, ödememeye meyillilik olarak etiketlemek doğru karşılanmamaktadır.⁷²

SCRA'ları belirlerken dikkat edilmesi gereken bir diğer husus ise bir çok banka ve şirket tarafından kredi kaybı hesaplamalarında kullanılan IFRS9 metodunun SCRA'lar ile olan ilişkisi ve uygulamasıdır. Kredi kayıpları SCRA belirlemelerinde kullanılan en temel öge olduğundan iki kavram arasında doğrudan bir ilişki vardır. IFRS9 muhasebe yaklaşımı çerçevesinde 3. Sınıf olarak etiketlenen ürünler genel olarak temerrüt olarak işaretlenmektedir. SCRA yaklaşımında aşağıda belirtilen durumlar hariç 3. Sınıf olarak işaretlenen ürünler temerrüt olarak sınıflandırılır⁷³:

- Gecikme gün sayısı sınırı olarak 90 gün yerine 180 gün kullanmayı seçen bankalar
- Sınıf 3 atamaları için materyallik eşik noktası kavramını kullanmayan bankalar da
- Teknik gecikme gün sayısı durumlarında
- Merkezi hükümetler, yerel yönetimler, ve devlet sektörlerine verilen kredilerde.

IFRS9 muhasebeleştirme bakış açısı tarafından ikinci sınıf olarak belirtilen krediler için, sınıflandırma gereği kredi kalitesinde bir düşüş var yorumu yapılabilse dahi, ikinci sınıf olmak CRR'de doğrudan bir temerrüt tanımı olarak belirtilmez. Ancak diğer ödememeye meyillilik kriterlerine de bakılması gerekir.

⁷² A.e. European Banking Authority.

⁷³ A.e. Manz.

2.1.1.2. Gecikme Gün Sayısı Kriteri

Ödememeye meyillilik kriteri bankanın müşterilerini henüz temerrüt olayı gerçekleşmeden belirli sebeplerden ileride yükümlülüklerini yerine getirmeyeceğine kanaat getirmesiyle temerrüt olarak belirlemesiyle, bir diğer temerrüt tanımı ise gerçekleşmiş olan durumlardır. Bir banka, müşterisinin 90 günden fazla gecikmesi olduğu takdirde temerrüt olarak sınıflandırmalıdır. Burada dikkat edilmesi konu materyallik eşik noktasıdır. Çok az miktarda riski olan bir müşterinin ödemesini geciktirmesi ile doğan temerrüt durumu müşterinin gerçek ekonomik durumunu yansıtmadığı gibi aynı zaman temerrüte giriş çıkışlarda çok oynaklığa sebebiyet vereceğinden belirli bir miktarın altındaki riskler için gerçekleşen gecikme gün sayısındaki artış temerrüt olarak işaretlenmemektedir. Bu materyallik eşik noktası bankalar tarafından değişiklik gösterebileceği gibi genel olarak 250 Euro olarak belirlenir. 250 Euro'nun altında riske sahip olan bir müşterinin gecikme gün sayısı artışa geçse bile bu müşteri temerrüt olarak işaretlenmez.⁷⁴

CRR 178. Madde 6. bent⁷⁵ gereği bankalar bir müşterinin gecikme gün sayısını sayarken dikkat edilmesi gereken bazı kurallar bulunmaktadır. İlk olarak müşteri ile yapılan kredi anlaşması ödemelerde erteleme, ödeme atlama veya ödeme takvimini değiştirme gibi şartları içeriyor ise bu sebeplerle yaşanan ödeme gecikmesi gecikme gün sayısı olarak sayılamamaktadır. Bu durumlarda gecikme gün sayısı yeni ödeme planı çerçevesinde ilk ödeme planından bağımsız bir şekilde hesaplanır. Kredi anlaşmalarındaki bu tarz haklar müşterilere bankalar tarafından çeşitli pazarlama stratejileri veya yerel düzenleyicilerin talepleri çerçevesinde konulmuş olabilir.

Aynı CRR maddesi gereği, hukuki sebeplerden ötürü atlanan ödemeler de gecikme gün sayısı kapsamın girmez. Bu durumlarda yükümlü hukuki açıdan ödeme sorumluluğunda olmadığından aynı şekilde ödemesi için gecikme gün sayısı sorumluluğundan da muaftır. Burada dikkat edilmesi gereken husus, genellikle bu tarz hukuki ödeme işlemlerinin müşterilerin içinde bulunduğu kötü finansal duruma işaret

⁷⁴ The Bank for International Settlements. Prudential treatment of problem assets - definitions of non-performing exposures and forbearance. (Çevrimiçi) Haziran 10, 2021.

⁷⁵ A.e. European Union s. 113.

ediyor olmasıdır. Burada bankalar diğer ödememeye meyillilik kurallarından müşteriye temerrüt olarak tanımlamaları yüksek ihtimaldir.

Teknik sebepler ile temerrüt olabilecek şekilde işaretlenmesi gereken durumlarda bankaların temerrüt işaretlemesi yapmaması gerekmektedir. Teknik sebepler ile kastedilen konular şunlardır:⁷⁶

- Veri veya sistem hataları sebebiyle gerçekleşen temerrüt tanımlamaları
- Ödeme sistemlerinin çökmesi sonucu gerçekleşen temerrüt tanımlamaları
- Müşterinin yükümlü olduğu miktarı gecikme gün sayısı eşik noktasından önce ödemesi ancak ödemenin bankaya ulaşımı sırasında yaşanan gecikmelerin sonucunda doğan temerrüt tanımlamaları
- Gerçekleşen faktöring anlaşmaları sonucunda gerçekleşen anlaşmalarda 30 günlük gecikme gün sayısının aşılması sonucunda gerçekleşen temerrüt tanımlamalarıdır.

Bahsedilen bu durumlarda gerçekleşen temerrüt tanımlamaları bankalar tarafından temerrüt olarak işaretlenmemelidir. Bu tarz teknik hatalardan doğan temerrüt tanımlamalarını engellemek için materyallik eşik noktası da kullanılan bir yöntemdir. Materyallik eşik noktasının konulmasının asıl amaçlarından biri de bu tarz temerrüt tanımlamalarını engellemektir. Merkezi hükümetlere ve yerel yönetimlere verilen kredilerin geri ödenmesi süreçlerinde, işlemlerde yaşanacak uzun süreçlerden ötürü bu tarz müşterilere tanınan gecikme gün sayısı eşik noktası 180 gündür. Burada dikkat edilmesi gereken nokta, bu tarz müşterilerin diğer temerrüt tanımlarına maruz kalmamalarıdır. Aksi takdirde diğer kurallar halen geçerli olmaktadır.⁷⁷

Temerrüt tanımı ile ilgili diğer dikkat edilmesi gereken noktalar ise, CRR 178. Madde 1. bent a fıkrası⁷⁸ gereği bir müşteri banka tarafından temerrüt olarak işaretlendikten sonra, banka halen müşterinin ödeyemeyeceğine kanaat getiriyorsa temerrütte durmaya devam eder. Müşterinin temerrüt tanımından çıkması için, 90

⁷⁶ A.e. European Banking Authority.

⁷⁷ A.e. The Bank for International Settlements.

⁷⁸ A.e. European Union s. 112.

günlük gecikme gün sayısından çıkması ve bankalar tarafından belirlenen deneme süresi boyunca (en az 3 ay) yine banka tarafından ödeme yapabileceğine kanaat getirilmesi gerekir. Eğer banka deneme süresi boyunca müşterinin ödeme yapabileceğine kanaat getirirse müşteri temerrütten çıkabilir, aksi takdirde halen temerrüt olarak işaretlenmiş olarak devam etmelidir. Burada amaçlanan birden çok temerrüt olayını azaltmaktır.

2.1.2. Kriz Dönemi Etkisi Yönergesi

IDD modellerinin en önemli karakteristik özelliklerinden birisi normal şartlara göre daha konservatif özellikte olmalarıdır. Bir başka ifadeyle normal olabilecek ihtimalleri değil de en kötü durumda olabilecek beklenmeyen zararları örnek vermek gerekirse %99'a kadar olan durumlarda kapsamak hedeflenmektedir. Amaç en kötü senaryoları dahi kapsamak olduğundan, geliştirilen modellerde tarihte yaşanmış olan kötü dönemlerin de etkilerinin olması dikkat edilmesi gereken bir noktadır. Bu konu CRR madde 153 ve madde 154'de bahsedilen risk ağırlığı fonksiyonlarında⁷⁹ %99.9'luk zararı kapsayan risk ağırlığı formüllerinde kullanılması gereken THK değerinin kriz dönemi ile ayarlanmış bir diğer deyişle artırılmış THK'lar olması gerekliliğini belirtmiştir. Bu noktada Basel kurallarının bahsedildiği Avrupa Birliği 575/2013 numaraları ve tarihli CRR'ın 181. Paragraf 3. Madde a bendi ve 182. Paragraf 4. Madde a bendi⁸⁰ gerekliliklerine itafen 16 Kasım 2018 tarihinde EBA tarafından Ekonomik Kriz Dönemlerinde THK Hesaplaması⁸¹ adı altında bir yönerge çıkartılmıştır. Bu yönergede Kriz döneminin nasıl belirlenmesi gerekliliği, hangi dönemleri ve durumları kriz dönemi olarak varsayılabilirliği, kriz döneminin uzunluğu ve kriz dönemlerinin modellere olan yansıması bir diğer deyişle miktarsallaştırılması konularından bahsedilmiştir.

Kriz dönemini belirlerken dikkat edilmesi gereken 3 husus vardır, bunlar kriz döneminin doğası, kriz döneminin önemi ve kriz döneminin uzunluğudur. Kriz

⁷⁹ A.e. European Union ss. 97-100.

⁸⁰ A.e. European Union ss. 116-118.

⁸¹ European Banking Authority. Guidelines for the estimation of LGD appropriate for an economic downturn ('Downturn LGD estimation'). (Çevrimiçi) Temmuz 17, 2021.

döneminin doğası kavramına bakıldığında, kriz dönemlerini belirlerken en önemli konu hangi makroekonomik değişkenlerin kullanılacağıdır. Her bir coğrafya, portföy, varlık sınıfı vs. değişik makroekonomik faktörlerden farklı şekillerde etkilenmektedirler, buna göre tek bir makroekonomik değişken ile yola çıkmak çok mantıklı bir hareket olmayacaktır. Kriz dönemini belirlerken hangi varlık grupları için hangi değişkenlerin dikkate alınması gerektiği yine aynı yönergede belirtilmektedir. Buna göre bütün varlık grupları için bu değişkenler şunlardır:⁸²

- Gayri safi Yurtiçi Hasıla,
- İşsizlik Oranı,
- Dışarıdan elde edilmiş Temerrüt Oranları,
- Dışarıdan sağlanan Kredi kayıpları miktarı.

Bu genel makroekonomik faktörlere ek olarak varlık gruplarına özel olan değerlendirilmesi gereken makroekonomik değişkenler de aşağıda belirtilmektedir :

- Kurumsal firmalar ve bireysel KOBİ'ler için, Sektöre özel endeksler – göstergeler,
- Bireysel müşteriler gayrimenkul ve konut kredileri için, Konut fiyatı endeksi – göstergesi,
- Kurumsal müşteriler gayrimenkul ve konut krediler için, Kurumsal konut fiyatı endeksi – göstergesi,
- Yukarıdaki kriterlerin dışında kalan diğer bireysel varlık sınıfları için ise, toplam hane halkı borç miktarı ve harcanabilir kişisel gelir miktarı (eğer erişilebilir ise).

Özelleştirilmiş kredi verme kurumları için⁸³,

- Konut kredisi ise konut fiyatı endeksi,
- Proje finansmanı ise söz konusu varlığın fiyatı,
- Obje finansmanı ise belirli teminatlar için olan endeksler,

⁸² A.e. EBA.

⁸³ A.e. EBA.

- Varlık finansmanı ise, varlık fiyatı veya endeksleri.

gibi makroekonomik değerlere bakılmalıdır. Bankalar bu değerleri hesaplamalarına birinci farklarını alarak miktarları yıllık değişimler olarak da inceleyebilirler. Kriz döneminin doğası bu makroekonomik değişkenleri inceleyerek belirlenir.⁸⁴

Kriz dönemi belirleme analizinde kullanılan bir unsur ise analiz edilen potansiyel kriz döneminin şiddetidir. Kriz döneminin şiddeti, analiz edilen minimum 20 yıllık geriye dönük dönemde bir makroekonomik değişkenin 12 ay boyunca üst üste ne kadar kötüleştiğinin analizidir. Bu analizde tarihsel veri içinde değişkenlerin en kötü seviyeye ulaştığı ve en az üst üste 12 ay kaldığı dönemler belirlenir, kriz dönemi için birden çok aday var ise, bir diğer deyişle birden çok dönemde normale göre bir kötüleşme görülüyor ise değerlerin hangi dönemde en kötü seviyede olduğuna bakılır ve o dönem seçilir.⁸⁵

Kriz dönemi belirleme analizi için bir diğer nokta ise analiz edilen kriz döneminin süresi bir diğer deyişle uzunluğudur. Kriz dönemi şiddetini belirlerken üst üste 12 ay için bakılması gerektiği belirtilmişti, 12 ay yönergelere göre minimum süre olarak kabul edilir⁸⁶, ancak bankalar bu değeri daha uzun olarak da belirleyebilmektedirler. Bu konuda bankalar önceden bahsedilen 2 kriterin üzerine (doğası ve şiddeti) bu kriterleri en az 12 ay boyunca sağlayan dönemleri kriz dönemi olarak kabul edebilirler. Bir başka deyişle belirlenen makroekonomik kriterlerin en kötü olduğu dönemler 12 aydan kısa ise (örneğin yalnızca 3 ay sürmüş ise) o döneme kriz dönemi denilemez ve model geliştirilirken o dönemi dahil etmek EBA standartlarınca kriz dönemini dahil etme şartını sağlamaz.

Kriz dönemi uzunluğu ile ilgili dikkat edilmesi gereken durumlardan biri de kriz döneminin 1 yıldan uzun süre olup, üst üste takip eden yıllarda değişmeden aynı


⁸⁴ Altman, E. I. (2011). Default recovery rates and LGD in credit risk modelling and Practice. *Economic Notes* 33(2), ss. 183-208.

⁸⁵ Neisen, M. (2021). Observations about the impact of a downturn period on the main components of the LGD Model - PWC Regulatory Blog. (Çevrimiçi) Ağustos 1, 2021.

⁸⁶ Caselli, S., S. Gatti, and F. Querci (2008). The Sensitivity of the Loss Given Default Rate to Systematic Risk: New Empirical Evidence on Bank Loans. *Journal of Financial Services Research* 34(1), ss. 1–34.

çizgide devam etmesi durumudur. Bu durumlarda kriz döneminin takip eden yılların tamamı olarak belirlenmesi gerekir. Bir örnek ile açıklamak gerekirse, Şekil 3’da rastgele olarak oluşturulan varsayımsal işsizlik oranı zaman serisine bakılacak olunursa, işsizlik oranının 2002’de en kötü noktaya ulaştığını görebilmekteyiz. Ancak aynı şekilde 2003 yılında da yatay bir çizgi ile en kötü değerini devam ettirdiği grafikte görülebilmektedir. Bu durumda kriz dönemini 2002-2003 yılı için uzatılmış olarak belirleyebilmekteyiz. Bu örnekte Kriz dönemi doğası olarak işsizlik oranı, şiddeti olarak en kötü olduğu nokta ve süresi olarak ise en az 1 yıl olmak üzere 2 yıl sürmesi olarak kriz dönemi belirlenmiştir.⁸⁷

Şekil 3 : Uzatılmış Kriz Dönemi Örneği, İşsizlik Oranı Zaman Serisi




Kaynak : European Banking Authority. (2018, Kasım). Guidelines for the estimation of LGD appropriate for an economic downturn ('Downturn LGD estimation'). Temmuz 17, 2021, <https://www.bankofengland.co.uk/-/media/boe/files/prudential-regulation/policy-statement/2021/october/downturn-lgd-estimation-gl.pdf>.

Ekonomik kriz belirlemede süre faktöründe bir diğer dikkat edilmesi gereken nokta ise aynı makroekonomik faktörde takip eden yılda gecikmeli olarak aynı

⁸⁷ A.e. EBA.

sebepten oluşan tavan yapma (veya dip yapma) noktalarının da dikkate alınması gerekliliğidir. Buna bir örnek vermek gerekirse, Şekil 4’da yine ekonomik kriz doğası gereği işsizlik oranı ile oluşturulan zaman serisine bakıldığında 2003 yılındaki tavan noktasından sonra 2005 yılında da neredeyse aynı seviyede bir işsizlik tavan noktası görülmektedir. Bu noktada kriz dönemi her iki yılı da kapsayıp, 2003-2005 yılları arası olarak alınmalıdır.

Şekil 4 : Takip Eden Yıllar için Uzatılmış Kriz Dönemi Örneği, İşsizlik Oranı Zaman Serisi




Kaynak : European Banking Authority. (2018, Kasım). Guidelines for the estimation of LGD appropriate for an economic downturn ('Downturn LGD estimation'). Temmuz 17, 2021, <https://www.bankofengland.co.uk/-/media/boe/files/prudential-regulation/policy-statement/2021/october/downturn-lgd-estimation-gl.pdf>.

Kriz dönemini belirlerken dikkat edilmesi gereken bir diğer nokta ise, kriz dönemlerinin birden fazla makro ekonomik değişkenden oluşabileceğidir. Böyle durumlarda kriz döneminde farklı değişkenler aynı anda tepe noktasına ulaşmıyor olabilirler ancak kriz dönemini oluşturan – belirleyen bu değişik tepe noktası zamanlarının hepsinin ekonomik kriz dönemi içine dahil edilmesi önemli bir noktadır. Bir örnek ile açıklamak gerekilirse, Şekil 5’de kırmızı çizgi GSYH’deki büyümeyi göstermektedir, mavi çizgi ise üretim endeksini. Her iki değişken de aynı yıl içerisinde

olmasa da bir yıl arayla en kötü dip noktalarına ulaşmaktadırlar. Bu nokta GSYH için 2010 yılı iken üretim endeksi için 2009 yılı olarak görülebilmektedir. Aynı anda olmasa da bu iki dip noktanın ortak bir kriz döneminden çıktığı belirlenirse bankalar modellerinde kriz dönemi olarak 2009 ve 2010 yılını almaları gerekmektedir.

Şekil 5 : Farklı ekonomik faktörlerin korrele olmaları durumunda uzatılmış kriz dönemi belirleme – GSYH ve Üretim endeksi zaman serileri




Kaynak : European Banking Authority. (2018, Kasım). Guidelines for the estimation of LGD appropriate for an economic downturn ('Downturn LGD estimation'). Temmuz 17, 2021, <https://www.bankofengland.co.uk/-/media/boe/files/prudential-regulation/policy-statement/2021/october/downturn-lgd-estimation-gl.pdf>.

Bu noktada bankaların dikkat etmeleri gereken husus bu iki makro ekonomik değişkenin kısa süre ara ile dip noktaya ulaşmalarında bir ilişkinin – korelasyonun olup olmadığının belirlenmesi gerekliliğidir. Ancak böyle bir ilişki belirlendikten sonra kriz dönemi uzatılmış olarak belirlenebilmektedir.

Önceden bahsedilen komşu yıllarda bir yıl arayla dip nokta yapılması ile son örnekte bahsedilen farklı makro ekonomik değişkenlerdeki ardı ardına gelen dip noktaların uzatılmış bir kriz dönemi belirlemede kullanılmalarına ek olarak bu iki durumun da aynı anda görüldüğü kriz dönemleri de olabilmektedir. Bankalar bu

durumları beraber analiz edip ona göre uzatılmış kriz dönemlerini belirlemektedirler. Şekil 6’de örneği görülebileceği gibi, mavi çizgi bir diğer deyişle üretim endeksinde 1 yıl arayla hem 2007 yılında hem de 2009 yılında iki yakın dip noktası görülmektedir. Kırmızı çizgiyle belirtilen GSYH miktarı ise hemen ardına 2010 yılında dip yapmaktadır. Bu örnekte önceden bahsedilen iki durum da görülebilmektedir. Bu dip noktalar arasında bir ilişki belirlenebilmesi durumunda bankalar modellerinde dikkate alacağı kriz dönemini 2007-2010 yılları arasında belirlemek durumundadırlar.

Şekil 6 : Korele makro ekonomik değişkenler ve komşu yıl dip noktası sebebiyle uzatılmış kriz dönemi belirleme



Kaynak : European Banking Authority. (2018, Kasım). Guidelines for the estimation of LGD appropriate for an economic downturn (‘Downturn LGD estimation’). Temmuz 17, 2021, <https://www.bankofengland.co.uk/-/media/boe/files/prudential-regulation/policy-statement/2021/october/downturn-lgd-estimation-gl.pdf>.

Bankalar tarafından kriz dönemleri belirlenirken kullanılması gereken metodoloji EBA tarafından bu şekilde açıklanmaktadır. Bankalar içsel derecelendirme modellerinde (IDD) dikkate almaları gereken kriz dönemlerini belirledikten sonra bu

kriz dönemlerinin parametrelere yansımaları gerekmektedir⁸⁸. Buna kriz dönemlerinin miktarsallaştırılması adı da verilmektedir, kriz dönemleri parametrelere bir çarpan olarak yansıtıldıktan sonra modellerinin çıktıları bu çarpan ile çarpılıp daha da tutucu – konservatif bir hale getirilmektedir. Çalışmanın ilerleyen bölümlerinde geliştirilecek farklı makine öğrenmesi modellerinde basitliği sağlamak ve yalnızca değişik makine öğrenmesi yöntemlerinin belirlenen kriterlerde birbirleriyle karşılaştırılması hedeflendiğinden ve test edilecek olan model TO modeli olduğundan kriz dönemi gerekliliği modellere uygulanmayacaktır ve bütün modeller kriz dönemi konservatifliğinden bağımsız olarak karşılaştırılacaktır.

2.1.3. Temerrüt Oranı Modeli Gereksinimleri Yönergesi

EBA tarafından çıkartılan genel olarak IDD modelleri gereksinimleri hakkında ve IDD TO modeli özelinde diğer yönergelere ve gereksinimlere bakıldığında 21 Temmuz 2016 tarihli IDD modellerinin değerlendirilmeleriyle ilgili açıklamalar bulunan ‘IDD Değerlendirme Metodolojileri’ yönergesi⁸⁹, 20 Kasım 2017 tarihli IDD modelleri uygulayan bankalara yönelik anketlerin yer aldığı ‘IDD modelleme Uygulamaları raporu’ ve 20 Kasım 2017 tarihli TO ve THK modellerinin geliştirilmesi ve kalibre edilme gereksinimlerinin açıklandığı ‘TO belirleme, THK Belirleme ve temerrüte düşmüş varlıklar’ isimli yönerge ön plana çıkmaktadır. Bu yönergelerde bahsedilen temel gereksinimlerin yer aldığı ve bu gereksinimlerin ECB tarafından uygulamalarının nasıl kontrol edileceğini açıklayan Ekim 2019 tarihli ‘ECB İçsel Modeller Rehberi’ isimli dokümanlara değinilecektir.

TO Modelleri geçmiş veriye bağlı olarak istatistiksel modeller olup geleceğe yönelik tahmin yapmak için kullanılırlar. Bu modelleri sonuçları devamlı değişken olabilmekte ve sonsuz sayıda değer alabilmektedir. Model çıktılarının sonsuz değer alabilmesi çıktıların yorumlanabilirliğini düşürmekte ve değerlendirme yapmayı zorlaştırmaktadır. Her bir çıktı ihtimaline karşı ayrı bir yorumlama yapma gerekliliği

⁸⁸ A.e. EBA.

⁸⁹ European Banking Authority. (2017, Kasım). Eba report on İRB modelling practices. (Çevrimiçi) Temmuz 18, 2021.

bankalar ve denetleyici kuruluşlar için zorluk teşkil etmektedir. Bu açıdan EBA tarafından çıkartılan TO ve THK Hesaplamaları isimli yönergenin 66. Maddesinde belirtildiğine göre bankalar çıktılarını belirli sınıflara ayırmalıdır. Her bir sınıfın benzer risk karakteristiklerini göstermesi çok önemlidir. Bir sınıfın içerisinde atanmış müşteriler o sınıftan farklı bir davranış gösteriyor ise sınıflandırma doğru yapılmamış anlamına gelmektedir.

Atanması gereken sınıfların alt ve üst sınırları belirlendikten sonra bu sınıflara atanan müşterilerin hangi sabit TO değerini alacağı belirlenmelidir. Burada Uzun Dönem Ortalaması (LRA)⁹⁰ şeklinde yönergede bahsedilen, model geliştirildikten sonra model geliştirmesine ek olarak kullanılan kalibrasyon veri setinin geliştirilen model ile skorlanıp önceden belirtilen sınıflara ayrılıp daha sonrasında ise bu kayıtların – müşterilerin gerçekleşmiş olan bir yıllık gözlemlenen temerrüt oranları ortalamaları alınmasıyla elde edilen değerlerdir. Her bir yıl ve her bir sınıf için yapılan bu işlem daha sonrasında ise bir kere daha her bir yılın ortalaması alınmak üzere sınıflar bazında ortalamaları alınarak yapılmaktadır⁹¹. Sonuç olarak her bir sınıf için daha önce o sınıfta bulunacağına inanılan – öyle skorlanan müşterilerin gerçekten ne kadarının temerrüte düştüğü gözlemlenmiş veriden yola çıkarak hesaplanıp o sınıf için bir temsil değeri olarak bulunmaktadır. Bu işleme o sınıfa ait uzun dönem ortalaması denilmektedir. Uzun dönem ortalaması her bir sınıf için ayrı ayrı hesaplanmakta ve modelin kullanıma alınmasından sonra skorlanan müşteriler hangi gruba atanacağı belirlendikten sonra skordan bağımsız bir şekilde o grubun uzun dönem ortalamasını almaktadır.

Bir örnek ile anlatmak gerekirse bir kredi için bankaya başvuran müşteri kurulmuş olan model tarafından bilgileri kullanılarak skorlanır. Bankanın içsel temerrüt oranı modelinde kullanılan sınıflama Tablo 3'deki gibi olsun. Gruplama ve grupların skor aralıkları bankaların model geliştirme aşamasında benzer risk

⁹⁰ A.e. EBA.

⁹¹ Miu, P., & Ozdemir, B. (2008). Estimating and validating long-run probability of default with respect to Basel II requirements. The Journal of Risk Model Validation, 2(2), ss. 3–41.

karakterindeki müşterileri aynı sınıfa ayırmalarıyla belirlenmektedir, sınıfların uygun olup olmadıklarının test edilmesinden ilerleyen bölümlerde bahsedilecektir.

Tablo 3 : Uzun Dönem Temerrüt Ortalaması Örneği - Sınıflar

Skor	Grup	LRA
0-0.15	1	0,23
0.16-0.45	2	0,66
0.46-0.77	3	0,90
0.78-0.92	4	0,96
0.93-1	5	0,99

Tabloya göre TO modelinin skorlaması sonrasında 0-0.15 arası skor alan müşteriler birinci gruba, 0.16-0.45 arası skor alan müşteriler ikinci gruba atanması şeklinde bir sınıflama mevcuttur. Burada örneğin 0-0.15 arası bir model skoru alan müşterinin en sonunda sahip olacağı Temerrüt Oranı değeri 0.23 olacaktır. Bu değer model geliştirildikten sonra kalibrasyon veri setinde bu gruba ait müşterilerin gözlemlenen yıllara ve sınıflara göre olan ortalamalarıdır⁹². Örnekte bankaya başvuran müşterinin bilgileri Tablo 4’de verilmektedir. Bu müşteri bilgilerine göre müşteriye ait skor 0.22 olarak belirlenmektedir.

Tablo 4 : Uzun Dönem Temerrüt Ortalaması Örneği – Müşteri Bilgileri ve Skor

Müşteri No	Yaş	Gecikme Gün Sayısı	Gelir	Skor
42450	27	0	4000	0.22

Temerrüt Oranı 0.22 olarak hesaplanan müşteri ikinci sınıfta yer almaktadır. İkinci sınıfta yer alan müşterilere tahmin edilen TO değeri 0.66 olarak belirlendiğinden, 42450 numaralı müşteri için risk ağırlıklı varlık veya başvuru kabulü gibi işlemler yaparken uzun dönem ortalama değeri olan 0.66 dikkate alınacaktır. TO modellerinde sınıflara ayırma ve her bir sınıf için bir uzun dönem ortalama belirleme işlemine kalibrasyon işlemi denmektedir ve bu işlemin yapılması bölümün başında da belirtildiği gibi bir zorunluluktur.

⁹² Rauhmeier, R. (2011). PD-validation: Experience banking practice. The Basel II Risk Parameters, ss. 311–347.

TO ve THK modelleri hesaplamaları yönergelerinde belirtilen bir diğer gereklilik ise model kurulurken yaşanan sorunlara karşılık bir Konzervatiflik Marjı belirlmesi ve hesaplamasıdır. Konzervatiflik Marjı IDD modellerinde oldukça önemli bir konu olup modellerde gözlemlenen eksikliklerin hesaba katılması için gereklidir. Basel kurallarınca IDD modellerinde hesaba katılması gereken eksiklikler 2 temel kategoriye ayrılmıştır. Buna göre⁹³ :

Kategori A : Veri ve metodolojik eksiklikler

Kategori B : Kredi verme, Risk iştahı, tahsilat süreçleri gibi diğer belirsizlik yaratan durumlar

Bu temel kategorilendirmeye göre bankalar model geliştirirken olan değişiklikleri ve sorunları belirleyip bunlara yönelik uzun dönem temerrüt ortalamalarına ek olarak bir çarpan ile yansıtmaları gerekmektedir. Belirsizlik Marjları daha da alt kategorilere ayrılmaktadır, buna göre Kategori A için diğer bazı alt kategoriler şöyle sıralanabilir.⁹⁴

- Eksik veya değişen temerrüt kriterleri,
- Eksik veya değişmiş olan temerrüt tarihi,
- Bir önceki modelin sınıfları yeni modele girdi olarak kullanılıyorsa, o modele ait eksik veya değişmiş sınıf bilgileri,
- Eksik veya yanlış nakit akış kaynağı bilgileri,
- Tahsilatlar için kullanılan bilgide olan bir eksiklik veya yanlışlık,
- Ekonomik kayıp hesaplamada kullanılan veride bir eksiklik veya yanlışlık,
- Dış bir veri kullanımı durumunda kullanılan verinin mevcut durum ile örtüşmemesi,
- Uzun dönem ortalaması hesaplarırken alınan yıllık ortalamalarda kullanılan veride eksiklik veya yanlışlık,
- THK modellerinde kriz dönemi hesaplanırken kullanılan verideki eksiklik.

⁹³ A.e. Rauhmeier.

⁹⁴ A.e. Miu & Ozdemir.

olarak sıralanabilirken, Kategori B’de yer alan bazı temel maddeler aşağıdaki gibidir:⁹⁵

- Kredi verme standartlarında, risk iştahı, tahsilat süreçlerin gibi içsel işlemlerde meydana gelen değişiklikler,
- Model veri seti ile başvuru portföyü arasındaki uyumsuzluklar,
- Piyasa veya hukuki sistemdeki değişiklikler,
- Portföyün risk seviyesindeki öngörülen değişiklikler.

2.2. TO Modeli Tahminleme Modelleri

Temerrüt Oranı, bir müşterinin krediyi geri ödeyememe ihtimalini hesaplayan, sonuçta bir olasılık veren 0 ile 1 arasında bir değerdir. Bu olasılık değeri müşterinin krediyi geri ödeyememe olasılığını belirtiyor olup bankalar tarafından müşterinin riskinin belirlenmesi ve ona göre verilecek olan kararlarda kullanılmaktadır. TO modelleri geçmişteki daha önceden temerrüte düşmüş veya düşmemiş müşterilerin hangi bilgiler ile temerrüt olarak işaretlenip işaretlenmediğine göre istatistiksel yöntemler ile kurulan modeller olup yeni gelecek müşteriler – veya portföyde bulunan ama gelecekte bir daha ölçülmek istenilen müşterilerin risklerini belirlemek için kullanılırlar⁹⁶. Müşterinin temerrüte düşmesi 1 veya 0 olarak iki ihtimale dayanıp, bu sebeple de TO modelleri genellikle sınıflandırma modellerinden kurulmaktadır. Mevcut uygulamada birçok banka kullanılan makine öğrenmesi yöntemi Lojistik regresyon olup, aynı amaç ile kullanılabilecek lan diğer sınıflandırma algoritmaları da mevcuttur. Çalışmanın bu bölümünde mevcut uygulama olan Lojistik Regresyon modellerine ek olarak XG Boost, Rassal Orman, Yapay Sinir Ağları (YSA) ve Destek Vektör Sınıflandırma modelleri de nitel olarak karşılaştırılacaklardır. Bu karşılaştırmanın sonucu olarak bu modeller arasından hangi modelin hangi sebeplerden ötürü TO modelleri açısından kullanımının en uygun olduğuna kanaat getirilecektir.


⁹⁵ A.e. EBA.

⁹⁶ A.e. Rauhmeier.

2.2.1. Mevcut Uygulama – Lojistik Regresyon

Lojistik Regresyon, bir olayın gerçekleşip ya da gerçekleşmeyeceğini tahminlemek için kullanılan bir gözetimli öğrenme modelidir. Bu modele göre bir müşteri çoklu doğrusal regresyon modeline göre belirli bir skorun üzerinde değer alıyorsa müşteri 1 değeri ile işaretlenir, diğer türlü bu eşik değerinin altında ise 0 değeri ile işaretlenmektedir. Müşterinin bilgilerinin çoklu doğrusal regresyon ile analiz edilmesinden sonrasında elde edilen skor, sigmoid fonksiyon olarak nitelendirilen çıktısı 0 ile 1 arasında olan $1 / (1+e^{-t})$ fonksiyonuna sokulmaktadır⁹⁷. Bu fonksiyon ve elde edebileceği değerlerden oluşan grafik Şekil 7’de görülebilmektedir.

Şekil 7 : Sigmoid Fonksiyonu ve Grafiği



İçerisinde çoklu doğrusal regresyon modelini de barındıran Lojistik regresyon modelleri yine çoklu doğrusal regresyon ile ortak varsayımlara sahiptir. Bu varsayımların başlıcaları şu şekilde sıralanabilir:⁹⁸

- Doğrusal İlişki: Bağımlı değişkenler (x) ile bağımsız değişken arasında doğrusal bir ilişkinin bulunduğu varsayımı,
- Bağımsızlık: Hata miktarlarının verinin kendisi ile alakasız olduğu varsayımı,

⁹⁷ Stoltzfus, J. C. (2011). Logistic regression: A brief primer. Academic Emergency Medicine, 18(10), ss. 1099–1104.

⁹⁸ Uanhoro, J. O., Wang, Y., & O’Connell, A. A. (2019). Problems with using odds ratios as effect sizes in binary logistic regression and alternative approaches. The Journal of Experimental Education, 89(4), ss. 670–689.

- Eşvaryanslık: Hata paylarının miktarlarının bağımsız değişkenin büyüklüğü ile bir ilişkisinin olmaması varsayımı,
- Normallik: Hata paylarının normal dağıldığı varsayımı.

Bu varsayımlardan birinin sağlanmaması durumunda modelin çıktılarının tam güvenilir olması konusunda ciddi endişeler oluşabilmektedir.

2.2.1.1. Lojistik Regresyon Modellerinin Olumlu Yönleri

Lojistik Regresyon modellerinin kullanılmasındaki ve mevcutta bankalar tarafından tercih edilmelerinin altında yatan en büyük etken yorumlanabilir olmalarıdır. Öyle ki lojistik regresyon modellerinde her bir değişkende meydana gelecek bir birimlik değişimin tahmin edilmek istenen bağımlı değişkende ne miktarda bir değişiklik yaratacağı oranına Odds Oranı (OR) denilmektedir⁹⁹. Bu oran x bağımsız değişkeninin bir birim artırılması sonucunda bağımlı değişkenin, e (2.7182..) sayısının X değişkeninin katsayısı kadar kuvveti şeklinde artacağını belirtmektedir. Aşağıdaki denklem bu oranın nasıl ortaya çıktığına dair gösterimi içermektedir.¹⁰⁰

$$OR = \frac{odds(x+1)}{odds(x)} = \frac{\left(\frac{p(x+1)}{1-p(x+1)} \right)}{\left(\frac{p(x)}{1-p(x)} \right)} = \frac{e^{B(0)+B(1).(X+1)}}{e^{B(0)+B(1).x}} = e^{B(1)}$$

P(x): Bağımsız değişken x değeri iken olayın gerçekleşme olasılığı

B(n): N inci değişkenin katsayısı

Odds(x) : Bağımsız değişken X iken Odds değeri

Odds Oranı Lojistik regresyonun en büyük artılarından, özelliklerinden biri olan yorumlanabilirlik özelliğine yardımcı olan oranların başında gelmektedir.

Lojistik regresyonun diğer olumlu kısımları aşağıdaki gibi sıralanabilir:¹⁰¹

⁹⁹ Morgan, S. P., & Teachman, J. D. (1988). Logistic regression: Description, examples, and comparisons. *Journal of Marriage and the Family*, 50(4), s. 929.

¹⁰⁰ A.e. Uanhoro

¹⁰¹ Tu, J. V. (1996). Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. *Journal of Clinical Epidemiology*, 49(11), ss. 1225–1231.

- Bağımsız değişkenlerin uzayda dağılımları ile ilgili varsayımlar barındırmaması,
- Çoklu sınıflarda sınıflandırma için genişletilebilir olmaları (2'den fazla sınıf olması durumlarında),
- Bağımsız değişkenlerin regresyon denkleminde boyutları kadar (ne kadar büyük sayı oldukları) pozitif veya negatif yönde etkiye bulunduklarının da direkt olarak görülebilmesi (ilişkinin boyutunun yanı sıra yönünün de görünebilmesi),
- Basit veri kümelerinde iyi performans göstermeleri,
- Modelde bağımsız değişkenlerin sahip oldukları katsayılar ile kolayca değişken önem sıralamasının yapılabilmesi,
- L1 veya L2 düzenleme tekniklerinin uygulanabilir olması, bu sayede eğitilen veri setindeki değerlerin ezberlenmesinin önüne geçilebilmesi.

2.2.1.2. Lojistik Regresyon Modellerinin Olumsuz Yönleri

Lojistik Regresyon modellerinin kullanımının uygun olmadığı – olumsuz yönleri aşağıdaki gibi sıralanabilmektedir¹⁰².

- Gözlem sayısının düşük olduğu durumlar,
- Doğrusal sınırlamalar koyması,
- Bağımlı değişken ile bağımsız değişken arasında doğrusal ilişkinin olduğu varsayımı,
- Doğrusal olmayan problemlerin lojistik regresyon modeli ile çözilememesi,
- Lojistik regresyon modellerinde bağımsız değişkenler arasında az veya hiçbir ilişki olmaması gerekliliği,
- Ayrık veri ile bağımlı değişken tahmini yapması, bağımlı değişkenin sürekli veri olduğu durumlarda kullanılamaması.

¹⁰² A.e. Morgan & Teachman.

2.2.2. Alternatif Makine Öğrenme Modelleri

2.2.2.1. XG Boost Modeli

XG Boost modelleri Karar Ağacı bazlı, meyilli yükseltme yöntemini kullanan bir makine öğrenmesi algoritmasıdır. İçinde birden çok Karar ağacı makine öğrenmesi yapılarını barındırdığından XG Boost modelleri topluluk öğrenme yöntemi modelleri arasındadır¹⁰³. Meyilli yükseltme yönteminden kastedilen ve XG Boost modellerinin de tanımlaması olan algoritma, birden çok karar ağacı modeli ile her bir modelin çıktılarının gerçekleşmiş olan değerlerden farkı ile bir diğer deyişle hata payı ile diğer modelin girdisi olarak kullanılmasına denmektedir¹⁰⁴. XG Boost modellerinde her bir karar ağacı modeli önceki modelin hata paylarını bağımlı değişken olarak kullanıp her bir adımda hatayı azaltarak en aza indirmeyi amaçlarlar. Böylelikle ile kullanılan zayıf performanslı karar ağaçları, diğer modellere geçildikçe güçlenip daha yüksek isabetli sonuçlar vermektedir. Yükseltme modellerinde modeller birbirlerinin ardı sıra eğitilip kullanılmaktadır, paralel şekilde aynı anda tahmin yapmamaktadırlar.

XG Boost modellerinin çalışma şekilleriyle ilgili bir örnek vermek gerekilirse, Tablo 5'deki gibi bir veri kümesi olduğu varsayılın. Bu veri kümesinde müşterinin yaşı ile maaşı arasında bir tahminleme yapılmaktadır.

Tablo 5: XG Boost Örneği Veri Kümesi

Yaş	Maaş
5	82
7	80

¹⁰³ Peter Gachoki, Moses Mburu, Moses Muraya. Predictive Modelling of Benign and Malignant Tumors Using Binary Logistic, Support Vector Machine and Extreme Gradient Boosting Models. American Journal of Applied Mathematics and Statistics. 2019; 7(6): ss. 196-204.

¹⁰⁴ A.e. Chen & Guestrin.

12	103
23	118
25	172
28	127
29	204
34	189
35	99
40	166


Tablo 6’da F0 ile gösterilen XG Boost modeli içerisindeki karar ağaçlarından ilkinin bir diğer deyişle zayıf tahmin ediciye ait olan bir skordur. Görüldüğü üzere gözlemlenen maaş ile tahmin edilen maaş arasında oldukça fark olup, bu fark dördüncü sütunda $y - F0$ olarak gösterilmektedir.

Tablo 6 : XG Boost Örneği, İlk Tahmin Sonucu

x	y	F0	y - F0
5	82	134	-52
7	80	134	-54
12	103	134	-31
23	118	134	-16
25	172	134	38
28	127	134	-7
29	204	134	70
34	189	134	55
35	99	134	-35
40	166	134	32

İkinci aşamada, ikinci sırada gelen karar ağacı, ilk modelden elde edilen hata farkları ile bir diğer deyişle Tablo 6’da gösterilen dördüncü sütundaki değerleri kullanarak yeni bir tahminde bulunacaktır. İkinci karar ağacına ait, karar verme yaprakları bir diğer deyişle ağacın çalışma prensibi Şekil 8’de görülebilmektedir. Buna göre ağaç ilk ağacın hata paylarını bağımsız değişken olarak kullanıp, 23’den büyük değerler için 25.5 tahmin ederken, küçük değerler için -38.25 tahmin etmektedir.

Şekil 8 : İkinci Karar Ağacı Çalışma Prensipli



Buna göre ikinci karar ağacı tarafından yapılan tahminleme Şekil 9’de görülebilmektedir.

Şekil 9 : XG Boost Örneği, İkinci Tahmin Sonucu

x	y	F_0	$y - F_0$	h_1	F_1
5	82	134	-52	-38.25	95.75
7	80	134	-54	-38.25	95.75
12	103	134	-31	-38.25	95.75
23	118	134	-16	-38.25	95.75
25	172	134	38	25.50	159.50
28	127	134	-7	25.50	159.50
29	204	134	70	25.50	159.50
34	189	134	55	25.50	159.50
35	99	134	-35	25.50	159.50
40	166	134	32	25.50	159.50

Birbirleri ardına gelen karar ağaçları bir önceki karar ağacının hatalarını kullanarak modelleri eğitip ona göre bir çıktı vermektedir ve bu böyle belirlenen sayıda

karar ağacı sayısına kadar gitmektedir¹⁰⁵. XG Boost modellerinin Python kodu ile uygulaması **Şekil 10**'da görülebilmektedir.

Şekil 10 : XG Boost Modelleri Python Uygulama Kodu

```
38 model = XGBClassifier()
39
40 # Modeli eğitim veri kümesi üstünde kurmak
41 model.fit(train_x,train_y)
42
43
44 # Eğitim veri kümesi üzerinde tahmin yapma
45 predict_train = model.predict(train_x)
46 print('\nTarget on train data',predict_train)
47
48 # Eğitim veri kümesi üzerinde isabetlilik oranı belirlemek
49 accuracy_train = accuracy_score(train_y,predict_train)
50 print('\naccuracy_score on train dataset : ', accuracy_train)
51
52 # Test veri kümesi üzerinde tahmin yapma
53 predict_test = model.predict(test_x)
54 print('\nTarget on test data',predict_test)
55
56 # Test veri kümesi üzerinde isabetlilik oranı belirlemek
57 accuracy_test = accuracy_score(test_y,predict_test)
58 print('\naccuracy_score on test dataset : ', accuracy_test)
59
60
```

2.2.2.1.1.XGBoost Modellerinin Olumlu Yönleri

XG Boost algoritmasının güçlü olduğu noktalar ve kullanılmasının uygun olduğu durumlar aşağıda belirtilmektedir.¹⁰⁶

- Algoritmanın kolay yorumlanabilir ve anlaşılabilir olması, tahmin çıktılarının bu sebeple daha kolay yorumlanabilmesi,
- Meyilli yükseltme algoritmasının genellikle iyi sonuçlar vermesi ve aşırı ezberlemeye karşı etkili olması,
- Algoritmanın orta ve küçük ölçekli veri kümelerinde etkili sonuçlar vermesi ve az değişkenli yapılandırılmış veri gruplarında başarılı olması,
- Hem sınıflandırma, hem de tahminleme yapılabiliyor olması.

¹⁰⁵ Nielsen, D. (2016). Tree Boosting With XGBoost Why Does XGBoost Win "Every" Machine Learning Competition? (tez). Norwegian University of Science and Technology, Oslo, ss.32-40.

¹⁰⁶ Freund, Y. and Schapire, R. E. (1996). Experiments with a new boosting algorithm. In Saitta, L., editor, Proceedings of the Thirteenth International Conference on Machine Learning (ICML 1996), ss. 148–156.

2.2.2.1.2. XGBoost Modellerinin Olumsuz Yönleri

XG Boost algoritmasının zayıf olduğu yönler aşağıda belirtilmektedir.¹⁰⁷

- Eksik ve yapılandırılmamış veri kümelerinde etkili sonuçlar vermemesi
- Aykırı değerler olduğu durumlarda problem yaşamaları


2.2.2.2. Rassal Orman

Rassal Orman, birden çok karar ağacı modelinin bir araya gelmesi sonucu oluşmasından ötürü bir topluluk öğrenmesi modeli olup, gözetimli bir makine öğrenmesi algoritmasıdır¹⁰⁸. Birden çok sayıda bir araya gelen karar ağaçları birbirlerine paralel olarak çalışıp ayrı ayrı sonuçlar üretilir en sonunda o sonuçlardan ortak tek bir sonuç çıkmasıyla çalışmaktadır. Rassal Ormanları oluşturan karar ağaçları verinin değişik kısımlarıyla eğitilebilirler, bundan ötürü her bir ağacın farklı ayırma noktaları ile birbirinden farklı sonuçları olabilir. Karar ağaçlarının farklı karar vermeleri durumunda değişik ortak sonuç bulma yöntemleri vardır. Bunlarda birisi ise oy çokluğu yöntemidir. Buna göre 100 karar ağacından oluşan bir rassal ormandaki ağaçların 65'i temerrüt diye sonuca ulaşır diğer 35'i temerrüt değil sonucuna varırsa oy çokluğuna göre rassal ormanın sonucu temerrüt olarak belirlenmektedir. Tek bir karar ağacına ve sonuca göre dışarı çıkıp çıkmamaya dayalı bir karar ağacı örneği Şekil 11'de gösterilmektedir. Buna göre çeşitli kriterlerden sonra karar ağacı 'evet' veya 'hayır' şeklinde bir sonuç vermektedir. Bu tip birden çok karar ağacının oluşturduğu Rassal Ormanlarda da her bir karar ağacının verdiği sonuca göre ortak bir sonuç alınmaktadır.

¹⁰⁷ A.e. Nielsen

¹⁰⁸ Uddin, M. S., Chi, G., Al Janabi, M. A., & Habib, T. (2020). Leveraging Random Forest in micro-enterprises credit risk modelling for accuracy and interpretability. *International Journal of Finance & Economics* 5-(2) ss. 3-14.

Şekil 11 : Karar Ağacı Örneği



Kaynak : Uzun, E. (2019, Kasım 5). Decision Tree (Karar Ağacı): İD3 Algoritması – Classification(Sınıflama).Kasım27,2021, https://erdincuzun.com/makine_ogrenmesi/decision-tree-karar-agaci-id3-algoritmasi-classification-siniflama/.

Algoritmanın XG Boost algoritmasından farklı olan yanı, XG Boost algoritmasında karar ağalarının birbirine seri olarak birbiri ardına çalışmasıyken, rassal ormanlarda ağaçlar birbirlerinden bağımsız ve paralel olarak çalışmaktadırlar.

2.2.2.2.1. Rassal Orman Modellerinin Olumlu Yönleri

Rassal Ormanlar birden çok karar ağacından meydana geldiğinden ötürü normal – tek bir karar ağacına göre çok daha etkili ve isabetli sonuçlar vermektedirler. Buna ek olarak Rassal Ormanların diğer iyi olduğu durumlar aşağıda belirtilmektedir¹⁰⁹.

- Hem sınıflandırma, hem tahminleme modellerinde kullanılabilmektedirler,
- Hem kategorik hem de devamlı değişkenlerde kullanılabılırler,
- Eksik veriyi kendi içinde sınıflayabilir, eksik veri bir problem teşkil etmemektedir,

¹⁰⁹ A.e. Uddin.

- Standartlaştırma veya Normalleştirme gibi değişken boyutlandırma yöntemlerine ihtiyaç yoktur,
- Doğrusal olmayan ilişkiler bir problem teşkil etmemektedir,
- Aykırı değerler bir problem teşkil etmemektedir.

2.2.2.2.2. Rassal Orman Modellerinin Olumsuz Yönleri

Rassal Ormanların olumsuz yönleri aşağıda belirtilmektedir¹¹⁰.

- Karmaşıklık : Rassal Ormanlar yüzlerce karar ağacından oluşabilmektedirler. Her bir karar ağacı başlı başına bir algoritma olup yüzlercesi bilgisayar gücü ve hesaplama açısından çok yüklü olabilmektedir,
- Rassal Ormanlar içlerinde bulunan yüzlerce ağacın verdiği karardan yararlandıkları için kapalı kutu olarak bilinirler ve modelin çıktılarını yorumlamak oldukça güç olabilir. Hatırlatmak gerekir ki yorumlanabilirlik kredi riski modelleri için aranan en önemli özelliklerden biridir,
- Uzun eğitim dönemi : Çok fazla sayıda karar ağacı olduğundan modeli eğitmek uzun zaman alabilir.

2.2.2.3. K-Means Kümeleme Modeli

Birbirine benzeyen verileri ortak özelliklerine göre kümelemeye dayalı bir algoritma olan K-Means algoritması bir gözetimsiz öğrenme algoritmasıdır. Gözetimsiz öğrenme algoritmalarında veri kümesinde bağımlı değişkenler 1 veya 0 olarak işaretlenmemektedir, algoritma verileri benzer özelliklerine göre gruplara ayırıp kümeleme yapmaktadır¹¹¹.


Buna göre, önceden belirlenen grup sayısı kadar ağırlık merkezi oluşturuluncaya kadar her bir ağırlık merkezi tek tek uzaya yerleştirilmektedir. Uzaya yerleştirilen her bir ağırlık merkezinin etrafındaki ona yakın veriler mesafeyi minimumda tutacak şekilde o ağırlık merkezine atanmaktadır. Her bir ağırlık merkezi tek tek yerleştirilerek her birinin olabildiğince birbirinden uzak olup, ona atanan noktalarında toplam uzaklıkları

¹¹⁰ Wiesmeier, M., Barthold, F., Blank, B., & Kögel-Knabner, İ. (2010). Digital mapping of soil organic matter stocks using random forest modeling in a semi-arid steppe ecosystem. Plant and Soil, 340(1-2), ss. 7–24.

¹¹¹ Garbade, D. M. J. (2018, Eylül 12). Understanding K-means clustering in machine learning. Medium. (Çevrimiçi), Kasım 14, 2021.

minimum olacak şekilde belirlenmektedir. Şekil 12’de iki ağırlık merkezli en uygun noktalara yerleştirilmiş K-Means algoritması çıktısı görülebilmektedir.

Şekil 12 : K-Means Algoritması Çıktı Örneği



Kaynak: Garbade, D. M. J. (2018, Eylül 12). Understanding K-means clustering in machine learning. Medium. Kasım 14, 2021, <https://towardsdatascience.com/understanding-k-means-clustering-in-machine-learning-6a6e67336aa1>

K-Means algoritması bir gözetimsiz öğrenme yöntemi olup işaretlenmiş bağımlı değişkeni olan Temerrüt oranı modelleri için çok uygun olmamaktadır. Değerlendirme bölüm sonundaki sonuç kısmında yapılacaktır.

2.2.2.4. Destek Vektör Sınıflandırması


Kredi riski TO modellerinde kullanılabilecek bir diğer makine öğrenmesi algoritması da Destek Vektör Sınıflandırmasıdır (DVS). Bir gözetimli öğrenme algoritması olan Destek vektörleri genellikle sınıflandırma problemlerinde kullanılmaktadır. Bu açıdan kredi riski TO modellerine uygun olabilecek adaylar arasındadır.¹¹²

DVS algoritmasında veri setindeki her bir nokta n boyutlu bir nokta olarak ifade edilir. Burada n sayısı modelde sahip olunan değişken sayısına eşittir. Her bir veri noktası n boyutlu uzayda ayrı ayrı koordinatlara yerleştirildikten sonra iki sınıfa ait (veri

¹¹² Putri, N. H., Fatekurohman, M., & Tirta, İ. M. (2021). Credit risk analysis using support vector machines algorithm. Journal of Physics: Conference Series, 1836(1), 012039.

noktalarının temerrüt ya da temerrüt değil olması gibi) noktaları en iyi şekilde ayıran hiper-düzlemler çizilir. Bu çizilen düzlemler iki sınıf arasındaki noktaları olabilecek en yüksek sayıda ayıracak şekilde çizilmelidir. Örnek vermek gerekirse, Şekil 13'te kırmızı ve mavi noktaları ayırabilecek 3 tane A-B-C hiper düzlemi görülebilmektedir.


Şekil 13 : Destek Vektör Makinesi Örneği



Kaynak : Anshul Saini, Support Vector Machine(SVM): A Complete Guide for Beginners. Analytics Vidhya. (2021, Kasım 12).

Bu hiper düzlemlerden A ve C düzlemleri kırmızı ve mavi noktaları tam ayıramazken B düzlemi tamamen ayırabilmektedir. Bu yüzden B noktası DVS algoritmasının seçilen hiper düzlemi olacaktır. DVS algoritmalarına bir diğer örnek vermek gerekilirse Şekil 14'te kırmızı noktaların olduğu yerde bir adet de mavi nokta vardır. Bu durumda DVS algoritması çizdiği çizgiyi değiştirmeyip yine aynı doğrusal çizgiyi çizecektir. Böylelikle aykırı değerın algoritmanın genel performansına etkisi minimum düzeyde olacaktır.


Şekil 14 : Destek Vektör Makinesi Algoritması – Aykırı Değer Örneği



Kaynak : Anshul Saini, Support Vector Machine(SVM): A Complete Guide for Beginners. Analytics Vidhya. (2021, Kasım 12).

DVS’lerde dikkat edilmesi gereken bir diğer konu ise değişik şekilde konumlanmış verilerde tanımlanabilecek çekirdek fonksiyonları ile daha çok ayırma gücü olan düzlemler çizilebilmesidir. Bundan önceki örneklerde çizilen düzlemler hep doğrusal iken bu durum her türlü veri setinde iyi bir sonuç vermeyecektir. Örneğin Şekil 15’deki gibi bir veri setinde doğrusal bir düzlem ile kırmızıları mavilerden iyi bir şekilde ayırmak çok olası olmayacaktır. Böyle durumlarda tanımlanan çekirdek fonksiyonlarıyla veri noktalarını olabildiğince en iyi şekilde ayırabilecek şekillerde – fonksiyonlarda düzlemler çizmek gerekecektir.

Şekil 15 : Destek Vektör Makinesi Algoritması – Çekirdek Fonksiyon Örneği



Kaynak : Anshul Saini, Support Vector Machine(SVM): A Complete Guide for Beginners. Analytics Vidhya. (2021, Kasım 12).

DVS’lerde kullanılabilecek birkaç tane çekirdek fonksiyonları mevcuttur. Bunlardan başlıcaları önceki örneklerde gösterildiği üzere doğrusal fonksiyon, polinomal fonksiyon, Sigmoid fonksiyon ve Radyal bazlı fonksiyondur. Bu fonksiyonlar aşağıda gösterilmektedir.¹¹³

$$\begin{aligned} \text{Doğrusal} &= K(x_i, x_j) = x_j^T x_i \\ \text{Polinomal} &= K(x_i, x_j) = (x_j^T x_i + 1)^p \\ \text{Radyal Bazlı} &= K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \\ \text{Sigmoid} &= K(x_i, x_j) = \tanh(\alpha x_j^T x_i + \theta) \end{aligned}$$

p: Seçilen polinom derecesi

$K(x_i, x_j)$: i’inci ve j’ninci x değerleri için çekirdek fonksiyonu

α, θ : Kernel parametreleri

T: zaman ifadesi.

¹¹³ Yaman, A. & Cengiz, M. A. (2021). The Effects of Kernel Functions and Optimal Hyperparameter Selection on Support Vector Machines . Journal of New Theory , (34) , ss. 64-71 .

Bu tarz çekirdek fonksiyonlar yardımıyla değişik veri desenlerinde daha çok veriyi ayırabilecek, daha güçlü modeller yaratmak mümkün olacaktır.

2.2.2.4.1. Destek Vektör Sınıflandırması Modellerinin Olumlu

Yönleri

Destek Vektör Makineleri sınıflandırma algoritmalarının iyi bir sonuç verdiği, güçlü olduğu durumlar aşağıda sıralanmaktadır¹¹⁴ :

- Ayrım için belirli görülebilen bir veri deseni olduğu durumlarda,
- Çok boyutlu - çok değişkenlerin olduğu durumlarda,
- Az veri boyutunun olduğu durumlarda, özellikle boyut sayısının (değişken sayısının) veri sayısından olduğu durumlarda,
- Çok güçlü bir işletim sistemi, bilgisayar hafızasına ihtiyaç duymayan bir algoritmadır.

2.2.2.4.2. Destek Vektör Sınıflandırması Modellerinin Olumsuz

Yönleri

Destek Vektör Makineleri sınıflandırma algoritmalarının iyi sonuç vermediği, zayıf performans gösterdiği durumlar aşağıda sıralanmaktadır¹¹⁵ :

- Büyük veri kümelerinde,
- Veri kümesinde hedef değişkenlerde (bağımlı değişkenlerde) ortak özellikler fazla olduğunda – fazla sayıda hedef değişken olduğu durumlarda,
- Sınıflandırmalardaki olasılıkları elde etmek için yüksek hafıza ve işlemciye gerek duyulması.

¹¹⁴ Ashanira D., Azlan M., Roselina S., Overview of Support Vector Machine in Modeling Machining Performances, Procedia Engineering, Volume 24, 2011, ss. 308-312.

¹¹⁵ A.e. Yaman ss. 64-71

2.3. Modellerin Karşılaştırılması

Çalışmada, önceki bölümlerde bahsedilen Lojistik Regresyon, Rassal Orman, XG Boost, K-Means Kümeleme ve Destek Vektör modellerinin Temerrüt Oranı modellerinde uygulanabilirliği karşılaştırılmaktadır. Modeller karşılaştırılırken modellerin gözetimli öğrenme ile sınıflandırma yapabilmesi varsayılmaktadır. En baştan bu kritere uymayan modeller değerlendirmeden çıkartılacaktır. Modeller karşılaştırılırken öncelikle bir modelin neden uygun olmadığı belirtilerek eleme yöntemi uygulanacaktır. Sonrasında kalan modeller birer birer kendi aralarında karşılaştırılacaktır. Modellerin karşılaştırılmasında önemli bir nitel özellik olan modellerin çıktısının yorumlanabilir olması da ayrıca dikkate alınacaktır. Yorumlanabilirlik mevcut yöntem olan Lojistik regresyon modelinin sektörde bu amaçla kullanılmasının temel sebeplerinden birisi olmaktadır.

Bir sınıflandırma algoritması olan ve gözetimli öğrenme kullanılarak yapılması uygun olan Temerrüt Oranı modellerinde K-Means Kümeleme algoritmasının kullanımı çok uygun gözükmemektedir. Bahsedildiği üzere K-Means Kümeleme algoritması bir kümeleme algoritması olup veride temerrüt veya temerrüt olmama gibi etiketleri göz ardı etmektedir. Yorumlanabilirliğin de alt seviyede olduğu bu algoritma IDD TO modelleri için kullanıma uygun olmadığına karar verilmiştir. K-Means Kümeleme algoritmasının bir sonraki bölümde nicel analizi de yapılmayacaktır.

IDD TO modellerinde önceki bölümlerde bahsedildiği üzere en az 5-7 yıllık veri kullanılmalıdır. Bu sebeple IDD TO modelleri çok büyük veri ile oluşturulan modellerdir. Destek Vektör Modellerinin olumsuz yönlerinden biri olan büyük veri kümelerinde etkisizlik algoritmayı IDD TO modelleri için etkisiz bir aday yapmaktadır. Algoritma temerrüt ile temerrüt olmayan noktaları çok boyutlu uzayda etkili bir şekilde ayıracak düzlemleri çizerek fonksiyonları bulması oldukça zor olacaktır. Bu sebepten ötürü Destek Vektör modelleri de IDD TO modelleri için uygun aday olarak görülmemektedir.

Bölümde bahsedilen diğer gözetimli öğrenme yöntemlerine bakıldığında ise yüksek potansiyelli isabetlilik oranı, toplu öğrenme metodu olmaları gibi sebeplerden ötürü XG Boost ve Rassal Orman algoritmaları bir adım öne çıkmaktadır. XG Boost ve

Rassal Orman modelleri karşılaştırıldığında, Rassal Orman'ın aykırı değer, eksik veriye karşı olan güçlü performansı IDD TO modellerinde bölümün önceki kısmında bahsedilen Konzervatiflik marşu uygulamalarından ötürü çok bir ekstra katkı ifade etmemektedir. IDD TO modellerinde bankalar verideki eksik değerler için Konzervatiflik Marjı A kategorisi etki çarpanını uygulamak zorundadırlar. Bu gereklilik IDD modelleri gereklilikleri kısmında da belirtilmektedir. Bu sebepten ötürü her türlü eksik veri için bir tedavi uygulanacağından Rassal Ormanın en önemli avantajlarından birisi olan bu özellik bu durumda çok bir şey ifade etmemektedir.

Son dönemlerde gerçek durumlarda ve sektörde kullanılan makine öğrenmesi algoritmalarında oldukça yükselen bir grafik çizen XG Boost algoritması özellikle yorumlanabilir olması ile de bir adım öne çıkmaktadır. Birden çok karar ağacının seri olarak çalışmasının da faydasını gösterebilecek olan model nicel anlamda da iyi sonuçlar vermesi halinde oldukça ideal bir alternatif olarak görülmektedir.

ÜÇÜNCÜ BÖLÜM

MAKİNE ÖĞRENMESİ YÖNTEMLERİNİN KARŞILAŞTIRILMASI

3.1. Çalışmanın Amacı

Bu bölümde, nitel olarak karşılaştırılan modellerin nicel olarak IDD TO modelleri üzerinde karşılaştırılması yapılacaktır. Modellerin nicel karşılaştırılması belirlenen kriterler ile modellerin çıktıları üzerinden yapılacak olup, her model için aynı veri kullanılacağından modeller için kullanılan verinin kalitesi ile ilgili bir karşılaştırma yapılmayacaktır.

3.2. Veri Seti

IDD TO modelleri gözetimli öğrenme olduğundan bağımsız değişkenlerin yanı sıra her bir veri kaydının temerrüt olup olmadığı ile alakalı bir gösterge içermesi gerekir. Her bir modelin kurulumu için karşılaştırmayı daha etkin ve kolay hale getirmesi açısından aynı veri kümesinin kullanılmasına karar verilmiş olup, verinin ne modeli karmaşıktırarak kadar fazla değişken sayısına ne de çok basit hale getirecek kadar az değişken sayısına sahip olması göz önünde bulundurulmuştur.

Kredi riski modelleri için uygun olan finansal bilgiler ile temerrüt göstergesi içeren modellerin kurulumu için çok fazla zaman ve işlemci harcanacak kadar büyük olmayan veri seti, araştırmalar sonucunda aşağıdaki Kaggle platformu üzerinde bulunan bir projede kullanılmak için hazırlanan veri setinden alınmıştır.

‘<https://www.kaggle.com/karanagarwal/bankloans?select=bankloans.csv>’

Kaggle platformu veri bilimi alanında büyük şirketlerin de projelerini ve verilerin sunduğu, büyük para ödüllü yarışmaların da yapıldığı internet tabanlı bir veri bilimi ortamıdır. Bu ortamda şirketler kendi veri setlerini bazı değişiklikler yaparak ve gizliliklerini de gözeterek paylaşmaktadırlar. Veri seti platformda aynı amaç ile – kredi riski Temerrüt oranı tahminlemesi amacıyla konulmuş olup, biri temerrüt işareti olmak üzere toplamda 9 tane sütundan oluşmaktadır. Diğer bir deyişle veri kümesinde toplamda 8 tane bağımsız değişken mevcuttur. Veride bulunan bağımsız değişkenler

incelendiğinde bir müşterinin krediyi geri ödeyeme ihtimaline doğrudan etki edecek ve sektörde de temerrüt oranı modellerinde kullanılan maaş, yaş, borç miktarı oranları gibi değişkenler görülmektedir. Bu değişkenler veri kümesinde temerrüt oranı modelleri için uzun değişken listesi olarak uygun görülmektedir. Alınan veri kümesi İngilizce sütun isimlerine sahip olup bu sütunlar ve bağımsız değişkenler sırasıyla :

Age: Müşterinin yaşı,

Ed: Müşterinin eğitim seviyesi,

Employ : Müşterinin ne kadar süredir çalıştığı,

Address : müşterinin kaç yıldır aynı adreste yaşadığı,

Income : Müşterinin geliri,

Debtinc : Müşterinin borcu ile gelirinin oranı,

Creddebt : Müşterinin çektiği kredi miktarı ile borcunun oranı,

Othdebt : müşterinin borç miktarı,

Default : Temerrüt işareti (Bağımlı değişken).

şeklindedir. Veri kümesindeki sütunlar TO modeli geliştirilirken genelde kullanılan ve mantıken bir müşterinin temerrüte düşüp düşmeyeceğini analiz etmede kullanılan alanlardır. İş, yaş, gelir, borç oranları gibi değişkenler TO modelleri için kapsayıcı özellikler olduğundan veri seti proje kullanımı için uygun olarak değerlendirilmiştir. Verilen veri kümesi ile IDD TO modellerinin kurulumu ve kriterlerin ölçümü SAS programında yapılacak olup, verinin incelenmesi ile ilgili görseller Python dilinde oluşturulmaktadır. Burada Python dilinin veri analizi ve görselleştirmede daha etkili ve kullanışlı bir dil olması ön plana çıkmıştır.


3.2.1 Veri Kümesi Analizi

Veri kümesinin analizi önceki bölümde belirtildiği üzere Python ile yapılmaktadır. Analizde verideki bağımsız değişkenlerin bağımlı değişken ile olan birebir ilişkileri, bağımsız değişkenlerin kendi aralarındaki ilişkileri ile bağımsız değişkenlerin dağılımları incelenecektir.

İlk olarak bağımsız değişkenlerin birbirleriyle ve temerrüt işareti ile olan korelasyonlarının ısı haritası çizilmiştir. Korelasyon iki değişken arasındaki doğrusal

ilişkinin gücünü belirtmektedir¹¹⁶ ve bu ilişkinin bağımlı değişken ile bağımsız değişken arasında kuvvetli olması beklenirken, bağımsız değişkenlerin kendi arasında zayıf olması beklenir. Bunun sebebi bağımlı değişkendeki varyansın aynısını birden çok bağımsız değişkenin açıklamasından kaçınılmasıdır. Böyle durumlarda çok doğrusallık meydana gelip değişken (bağımsız değişken) seçimlerinde standart hata miktarları olduğundan fazla gözükp yanlış değişken seçimi prosedürü izlenmesi mümkün olabilir¹¹⁷. Bu sebeple bir modeldeki bağımsız değişkenler arasında ilişkinin minimum olması beklenir. Veri kümesindeki değişkenlerin korelasyon ısı haritası Şekil 16’da gösterilmektedir. Buna göre borç gelir oranı ile gelir arasında beklenen şekilde yüksek korelasyon gözükmemektedir. Aynı şekilde iş ve adres değişkenlerinin de bağımlı değişken ile bir diğer deyişle temerrüt işareti ile yüksek bir korelasyonunun olduğu görülebilmektedir.

Şekil 16 : Değişkenler arasında korelasyon ısı haritası



¹¹⁶ Bewick, V., Cheek, L. & Ball, J. Statistics review 7: Correlation and regression. Crit Care 7, 451 (2003).

¹¹⁷ A.e. Bewick.

Her bir değişkenin temerrüt işaretine göre nasıl dağıldığının grafiğini kedi bıyığı grafiği ile görselleştirilmiştir. İlgili grafikler Ek 3'te görülebilmektedir. Buna göre değişkenler arasında aşağıda belirtilen sonuçlara ulaşılabılır.

- Yaş olarak genç müşteriler, yaş olarak ileri müşterilere göre daha çok temerrüte düşmektedir,
- Kredi borç oranı yüksek olan kişiler beklenildiği üzere daha çok temerrüte düşmektedir,
- Daha uzun süre aynı adreste yaşayan kişiler daha az temerrüte düşmektedir,
- Daha yüksek borç gelir oranına sahip kişiler daha çok temerrüte düşmektedir,
- Daha az çalışma süresi olan kişiler daha çok temerrüte düşmektedirler.

Bir diğer analiz olan eksik değer ve aykırı değerlere bakıldığında veri kümesinde bağımsız değişkenlerde herhangi bir eksik değer ve önemli miktarda aykırı değer tespit edilmemektedir. Kullanılan veri kümesi az sayıda bağımsız değişkene sahip olup, kullanılan bağımsız değişkenler temerrüt oranına etkisi olabilecek değişkenler olarak görüldüğünden herhangi bir değişken seçimi çalışması yapılmamıştır.

3.3. Kriterler

Geliştirilecek olan farklı makine öğrenmesi modellerinin nicel olarak birbirleriyle karşılaştırılması için belirli kriterlerin seçimi gereklidir. Bu kriterler önceki bölümlerde bahsedilen EBA tarafından çıkartılan Genel TO modelleri gereksinimleri gibi modellerin nicel gereksinimlerinin anlatıldığı diğer yönergelerin de ışığında Basel Komitesi (BIS) tarafından çıkartılan 14. Çalışma Yönergeleri adı altında IDD modellerinin performanslarının değerlendirilmesinin anlatıldığı yönerge¹¹⁸ kullanılarak karar verilmiştir. Buna göre modellerin nicel olarak karşılaştırılacağı kriterler, modellerin ayırım gücü (ayrıştırıcı güç), modellerin tahminleme gücü ve model çıktılarının sınıflara ayrılmasından sonra sınıflar arasındaki dağılım (yoğunluk) olarak belirlenmiştir. Her bir kriterin detaylı tanımı ve ölçülmesinde kullanılacak olan araçlar – metotlar bölümün devamında belirtilmektedir.


¹¹⁸ The Bank for International Settlements. (2005, Mayıs 19). Studies on the validation of Internal Rating Systems (revised). (Çevrimiçi) Eylül 29, 2021.

3.3.1. Ayırıştırıcı Güç

Temerrüt Oranı modellerindeki temel amaç temerrüte düşmeyen müşteriye, temerrüte düşen müşteriye göre daha iyi bir skor vermektir. Diğer bir deyişle iyi müşteriye (temerrüte düşmeyen müşteriye), kötü müşteriden ayırmaktır. İyi müşteri ile kötü müşteri sıralamalarında bu farkın gözetilmesi beklenmektedir¹¹⁹.

Bu noktada bir modelin ayırıştırıcı gücü, o modelin temerrüte düşmüş bir müşteri ile temerrüte düşmemiş bir müşteriye ne kadar yüksek oranda ayırt ettiğine - sıralamada bir diğer deyişle skorda ne kadar farklı sıraladığına bağlıdır. Şekil 17 sıralamaya (skorlamaya) dayalı sınıflama modellerinde C eşik noktasına göre temerrüt olmayan müşterilerin skorlarının yüksek olduğu ve temerrüt olan müşterilerin skorlarının düşük olduğu beklentisini, göstermektedir. Buna göre ideal bir sınıflandırma modelinde soldaki kesim ile sağdaki kesimin tamamen ayrı olması – kesişen bir bölgenin olmaması beklenmektedir. Böyle durumlarda ayırıştırma gücü en yüksek olan modele ulaşılmış denmektedir.

Şekil 17 : Ayırıştırıcı Güç – Sıralama Grafiği



Kaynak : The Bank for International Settlements. (2005, Mayıs 19). Studies on the validation of Internal Rating Systems (revised). Eylül 29, 2021, https://www.bis.org/publ/bcbs_wp14.htm

¹¹⁹ Blöchwitz, S. (2008). Validation of Banks' internal rating systems: A challenging task? The Journal of Risk Model Validation, 1(4), ss. 3–16.


Bir modelin ayrıştırıcı gücünü ölçmek için kullanılabilecek olan yöntemlerin başında Eğrinin Altındaki Alan (AUC) değeri gelmektedir. AUC değeri Alıcı Çalışma Karakteristiği (ROC) eğrisi altında kalan bölgenin alanının hesaplanmasıyla elde edilmektedir. Bu alan Şekil 18’de sarı ile gösterilen bölgeye denk gelmektedir. ROC eğrisi y ekseninde farklı kesişim noktaları (C) için sınıflayıcı modelin ne kadar gerçek değeri doğru tahmin ettiğini belirtmektedir. Bu tanıma hassasiyet veya vurma oranı (HR) de denilebilir¹²⁰. ROC eğrisinin x ekseninde ise farklı eşik noktalarında (C) yanlış alarm oranları yer almaktadır. Yanlış alarm oranı sınıflayıcının ne kadar doğru olan bir durumu reddettiğini göstermektedir. ROC eğrisinde bu iki değer farklı eşik noktaları ile değişimleri gösterilmektedir, diğer bir deyişle ne kadar doğruyu reddettikçe o kadar çok yanlış da reddetmiş olduğunu göstermektedir¹²¹. Ayrıştırma gücü yüksek olan iyi modellerde, olabildiğince az sayıda doğru reddedilerek aynı zamanda o kadar çok isabetli tahmin yapılmaktadır. Buna göre olabilecek en iyi model Şekil 18’de de görüleceği üzere isabetin her zaman yüzde yüz olduğu ve bütün temerrüt müşterilerinin en düşük risk skorunda hali hazırda yakalanmış olduğu modellerdir¹²². Aynı şekilde olabilecek en kötü model sıralamanın tamamen rastgele yapıldığı köşegenden geçen çizginin çıktılarını ifade ettiği rastgele olarak sıralayan modeldir.

¹²⁰ Engelman, B., & Rauhmeier, R. (2014). The basel Ii risk parameters estimation, validation, stress testing - with applications to loan risk management (2nd ed.). Springer Berlin.

¹²¹ Blochwitz, S., Martin, M. R., & Wehn, C. S. (n.d.). Statistical approaches to PD validation. The Basel II Risk Parameters, Basılı, ss. 289–306.

¹²² Leippold, M. (2006). Testing Probability Calibrations: Application to Credit Scoring Models. Working Paper No. 323 Zurich.

Şekil 18 : ROC Eğrisi



Kaynak : The Bank for International Settlements. (2005, Mayıs 19). Studies on the validation of Internal Rating Systems (revised). Eylül 29, 2021, https://www.bis.org/publ/bcbs_wp14.htm

Şekilde ROC eğrisinin altında kalan A ile gösterilen alan AUC değerini göstermektedir, bu alan ne kadar yüksek olursa modelin ayrıştırma gücü o kadar yüksek demektir.

AUC değerinin istatistiksel olarak yorumlanması Mann-Whitney U istatistiği yardımıyla yapılmaktadır. Bu istatistiğe göre skoru daha yüksek olan müşterinin temerrüt ihtimalinin daha düşük olması beklenmektedir. Örnek olarak r'ler risk skoru olmak üzere,

$AA = r(a) > BBB = r(b)$ ise bir diğer deyişle a'nın risk skoru b'den daha iyi ise o zaman :

$TO(a) < TO(b)$ olarak beklenmelidir.,

Bu varsayımdan yola çıkarak, a ile gösterilenlerin gözlem dönemi sonrasında temerrüte düşmüş müşteriler olduğu verilirse, b ile gösterilenlerin ise aynı zamanda temerrüte düşmeyenler olduğu verilirse o zaman her A ve B çifti için aşağıda gösterilen şekilde u değeri hesaplanmaktadır¹²³.

$$u_{a,b} := \begin{cases} 1, & \text{eğer } r(a) < r(b), \\ \frac{1}{2}, & \text{eğer } r(a) = r(b), \\ 0, & \text{eğer } r(a) > r(b). \end{cases}$$

$r(a)$: a müşterisinin – temerrüte düşen müşterinin kredi skoru

$r(b)$: b müşterisinin – temerrüte düşmemiş müşterinin kredi skoru

U değerlerinin hesaplanmasından sonra, U istatistiği ise aşağıda gösterildiği üzere hesaplanmaktadır.

$$U := \sum_{(a,b) \in A \times B} u_{a,b} = |\{(a,b) \in A \times B | r(a) < r(b)\}| + \frac{|\{(a,b) \in A \times B | r(a) = r(b)\}|}{2},$$

$r(a)$: a müşterisinin – temerrüte düşen müşterinin kredi skoru

$r(b)$: b müşterisinin – temerrüte düşmemiş müşterinin kredi skoru

U : U değeri

U değeri hesabından sonra AUC değeri aşağıdaki gibi hesaplanmaktadır.

$$AUC := \frac{U}{|A| \cdot |B|} \in [0,1].$$

A : Toplam a müşterisi sayısı – temerrüte düşen müşteri sayısı

B : Toplam b müşterisi sayısı – temerrüte düşmeyen müşteri sayısı

U : U değeri

Grafikten ve hesaplamadan da anlaşılacağı üzere, AUC değeri 0 ile 1 arasında bir değer alabilmekte olup, 1'e doğru yaklaştıkça bu modelin ayrıştırıcı gücünün

¹²³ A.e. BİS wp14.

arttığını göstermektedir. Nicel araştırma sırasında modellerin ayrıştırıcı güçleri karşılaştırılırken AUC değerinden yararlanılacaktır.

3.3.2. Yoğunluk

Modellerin temerrüte düşme olasılığı olarak 0-1 arasındaki çıktıların aynı karakteristik özelliklere sahip olduğu sınıflara ayrılmaları gerekliliğinden önceki bölümlerde bahsedilmişti. Bu gereklilik EBA'nın çıkarttığı IDD TO modelleri gereksinimleri yönergesinde belirtildiği üzere IDD modellerinde sağlanması gerekmektedir. Kalibrasyon veri kümesinde skorlanan müşteriler sınıflara ayrıldıktan sonra sınıfların yoğunluğunun bir diğer deyişle sınıflara dağılan müşteri sayısının birbirlerinden çok farklı olmaması beklenmektedir. ECB kredi riski validasyon raporlama yönergesinde bu madde reyting sınıflarının anlamlı ve eşit bir şekilde dağıtılması gerekliliği olarak belirtilmektedir¹²⁴.

Çalışmada kurulan modeller, temerrüte düşme olasılığı çıktılarına bakılarak:

$0 \leq TO < 0,1$	Birinci Sınıf
$0,1 \leq TO < 0,2$	İkinci Sınıf
$0,2 \leq TO < 0,3$	Üçüncü Sınıf
$0,3 \leq TO < 0,4$	Dördüncü Sınıf
$0,4 \leq TO < 0,5$	Beşinci Sınıf
$0,5 \leq TO < 0,6$	Altıncı Sınıf
$0,6 \leq TO < 0,7$	Yedinci Sınıf
$0,7 \leq TO < 0,8$	Sekizinci Sınıf
$0,8 \leq TO < 0,9$	Dokuzuncu Sınıf
$0,9 \leq TO < 1$	Onuncu Sınıf

¹²⁴ European Central Bank. (2019, Şubat). Instructions for reporting the validation results of internal models. (Çevrimiçi) Eylül 2021.

Şeklinde sınıflara ayrılacaklardır. Temerrüt oranı modellerinde bankalar çeşitli sınıflara ayrılma yöntemleri kullanıyor olup, bu çalışmada basitleştirmek adına yukarıdaki gibi bir sınıflandırma uygulanacaktır.

Sınıflara ayrıldıktan sonra her bir modelin sınıf yoğunluğu birbirleriyle karşılaştırılırken Herfindahl Endeksi (HI) kullanılacaktır. Bu değer normalde piyasa yoğunluğunu ölçmek için kullanılmaktayken ECB kredi riski modelleri validasyonu raporunda¹²⁵ bahsedildiği üzere IDD TO modelleri çıktılarının sınıflara dağılımlarında da kullanılabilmektedir.

İlk olarak varyans katsayısı (CV) değeri hesaplanmalıdır. CV hesaplanırken K toplam sınıf sayısını belirtirken, R ise her sınıfın toplamdaki payını göstermektedir.¹²⁶

$$CV_{curr} = \sqrt{K \sum_{i=1}^K \left(R_i - \frac{1}{K}\right)^2},$$

K : Toplam sınıf sayısı

R_i : i sınıfındaki müşteri sayısının toplam müşteri sayısındaki payı

Dağılımdaki varyans katsayısı bulunduktan sonra, değeri kullanarak Herfindahl Endeksi sınıf dağılımı için aşağıdaki formül ile hesaplanır.

$$HI_{curr} = 1 + \log \left(\frac{CV_{curr}^2 + 1}{K} \right) / \log(K),$$

K : Toplam sınıf sayısı,

CV : Varyans katsayısı.

¹²⁵ European Central Bank. (2019, Şubat). Instructions for reporting the validation results of internal models. (Çevrimiçi) Eylül 25, 2021.

¹²⁶ A.e. ECB

Her bir modelin çıktılarının sınıflara dağılımı için bulunan HI değeri 0 ile 1 arasında değişmekte olup düşük olması dağılımın daha az bir diğer deyişle sınıfların daha eşit dağıldığı anlamına gelmektedir. Çalışmada HI karşılaştırılırken değerin düşük olması daha tercih edilebilir olacaktır.

3.3.3. Tahminleme Gücü

Çalışmada kullanılan bir diğer ölçüt ise model tahmin etme gücüdür. Tahminleme gücü modelin sınıflara ayrıldıktan sonra her bir sınıfın sahip olduğu uzun dönem Temerrüt Oranının her bir sınıf için ne derecede etkili bir şekilde tahmin ettiğini ölçmektedir¹²⁷. Ayırıştırıcı güç bir modelin iyi ile kötüyü ne kadar iyi ayırt ettiğini gösterirken tahmin etme gücü ise modelin sınıflarına belirlenen uzun dönem olasılık oranlılarının ne derece iyi tahminlediğinin ölçütüdür¹²⁸. Tahminleme gücü hesaplanırken kullanılacak araç ECB'nin Kredi riski modelleri validasyonu raporlama dokümanında¹²⁹ bahsedildiği üzere Jeffrey Testi olacaktır.

Jeffrey Testinde sıfır hipotezi sınıflar için tahmin edilen uzun dönem TO değerlerinin gerçekte gözlemlenenlerde büyük olduğu şekilde kurulmuş olup tek taraflı bir hipotez testi uygulanacaktır. Testin amacı bağımsız gözlemlerden oluşan binomsal modelde tahmin edilen temerrütler ile gözlemlenenleri karşılaştırmaktır. Jeffrey testinde öncül dağılım binomsal olacak olup, ikincil dağılım ise $a = D + 1/2$ ve $b = N - D + 1/2$ şekil parametrelerine sahip Beta Dağılımıdır. Buradaki D gözlem süresindeki temerrüt olmuş müşteri sayısını gösterirken, N ise toplam müşteri sayısını göstermektedir. Test sonucunda çıkacak olan p-değeri sonrasında sıfır hipotezi ışığında modelin tahmin etme gücü hakkında bir sonuca varılabilecektir.¹³⁰

¹²⁷ Prorokowski, L. (2019). Validation of the backtesting process under the targeted review of internal models: Practical recommendations for probability of default models. Journal of Risk Model Validation 13(2) ss.109-147.

¹²⁸ Tasche, D. (2003). A traffic lights approach to PD validation Working Paper, Deutsche Bundesbank.

¹²⁹ A.e. ECB.

¹³⁰ A.e. Tasche.

3.4. Kriterlerin Önem Derecesi

Kurulan modeller önceki bölümde bahsedilen 3 kriter ışığında birbirleriyle karşılaştırılmıştır. Toplam 4 tane model karşılaştırıldığı için ve karşılaştırmanın daha kesin - nicel – sonuçlar ile kolayca yapılabilmesi için her kriterde en iyi olan modele 4 puan verilecektir. Diğer derecedeki modeller ise sırasıyla 3, 2 ve en kötü sırada olan 1 puan olmak üzere her kriterden puanlanacaklardır. Daha sonrasında her bir kriterin de birbirinden önemlerine göre farklı katsayıları olacaktır. Buna göre ayrıştırıcı güç kriteri 2 ile çarpılırken, Yoğunluk kriteri 0,5 ile çarpılıp Tahminleme Gücü kriteri ise olduğu gibi puana yansıyacaktır. TO modellerinin özellikleri ve amacı gereği ayrıştırma özelliğinin daha çok önemli olmasından ötürü önem katsayısı 2 ile çarpılmaya karar verilmiştir. Yoğunluk skorlanan her bir müşterinin sınıflara ayrılmasından sonra sınıfların ne kadar eşit- homojen dağıldığının bir göstergesi olduğundan sınıflandırma metodolojisinin de etkisi bu kriterde hissedilmektedir. Bundan ötürü bu kritere doğrudan modelin performansı açısından bir anlam yüklemenin doğru olmayacağı düşünüldüğünden 0.5 ile çarpılmasına karar verilmiştir.

3.5. Modellerin Analizi

Kurulan 4 farklı model önceki bölümlerde bahsedildiği üzere 3 farklı kriter üzerinden değerlendirilmektedir. Modellerin kurulumu ve değerlendirmesi SAS programı ile yapılmıştır. Rassal Orman modelinin kurulumu SAS programının modeli öncelikle bilgisayara kaydetmesi gerekliliğine bağlı olarak programın kullanıldığı şirketin erişim engelinden ötürü Python 'da geliştirilip skorlanmıştır ancak devamındaki testler yeniden SAS programı üzerinden yapılmıştır. Modellerin geliştirildiği SAS akış şemaları Ek 4'de görülebilmektedir. Buna ek olarak Rassal Orman Python geliştirme kodları ise Ek 5'te bulunmaktadır.

Ek 4'de görülen SAS akış şemalarında gözükten programların içerisinde her bir modelin geliştirilmesinde kullanılan kodlar mevcuttur. Bu programlarda yer alan ve genel model geliştirme ve test etmede kullanılan kütüphane atama ve girdi analizi kodları Ek 6'da görülebilmektedir. Buna ek olarak modellerde kullanılan veri kümesindeki her bir bağımsız değişkenin dağılımlarının incelendiği frekans grafikleri ise Ek 7'de gösterilmiştir.

Modellerin karşılaştırılmasında kullanılan ayırt edici güç kriterini ölçmek için kullanılan AUC değerinin SAS programı üzerinden hesaplandığı kodlar Şekil 19’de görülebilmektedir. Buna göre belirtilen SAS fonksiyonu (makrosu) bütün modellerde kullanılacak olan girdiler değiştirilerek kullanılabilir. Her bir modelde kodun (makronun) uygulanması ilgili bölümde belirtilecektir.

Şekil 19 : AUC Hesaplama Kodu - SAS

```

13
14 %put &categories;
15
16 %do j = 1 %to %sysfunc(countw(&varlist));
17 %let i = %scan(&varlist, &j, ' ');
18 %put &i;
19
20 %do k=1 %to %sysfunc(countw(&categories));
21 %let t = %scan(&categories, &k, ' ');
22
23
24 proc sql noprint;
25     drop table c_stat_ungr_tmp1;
26     drop table c_stat_gr_tmp1;
27 quit;
28
29 ods output association=c_stat_ungr_tmp1 ; * Cikti Tablosunu olusturma;
30
31 proc logistic data=database(where=(&segm_var.=&scan(&categories, &k, ' ')));
32     model &target (event='1')= &i ;
33     oddsratio &i. ;
34 run;
35
36 %if %sysfunc(exist(c_stat_ungr_tmp1)) %then %do;
37     proc sql noprint;
38         create table CSTAT_&t. as
39         select cvalue2
40         from c_stat_ungr_tmp1
41         where Label2 = 'c';
42     quit;
43 %end;
44 %else %do;
45     data CSTAT_&t.;
46     cvalue2=" ";
47     cvalue2="N/A";
48     run;
49 %end;
50
51

```

Modellerin karşılaştırılmasında kullanılan bir diğer kriter olan yoğunluk kriterinin ölçülmesi için kullanılmasına karar verilen Herfindahl Endeksi’nin ölçümü her bir model için skorlanmış olan ve sınıfları atanmış olan veri kümelerinin her bir sınıf bazında o sınıfa ait olan müşteri sayısının SAS programı ile Şekil 20’de gösterilen sorgu aracılığıyla hesaplanması sonucunda bulunmaktadır.

Modellerin Tahminleme gücü analizleri için kullanılan Jeffrey testi de aynı Herfindahl Endeksi gibi girdileri ilk olarak SAS programından alınıp sonrasında Excel yardımıyla hesaplanmıştır. Jeffrey Testi için SAS programında kullanılan akış şemasındaki programlar ve programlardaki sorgular Ek 8’de görülebilmektedir. SAS sorgularının çıktılarının kullanıldığı ve hesaplamaların yapıldığı Excel’in ekran görüntüsü ise Şekil 22 de gösterilmektedir.

Şekil 22 : Jeffrey Testi Uygulanması - Excel

Sinif	Hesaplanan TO	Musteri Sayisi	Temerrute Dusen Musteri Sayisi	Alfa	Beta	P-Degeri
1	0.010781671	391	6	6.5	385.5	0.18461
2	0.055172414	162	13	13.5	149.5	0.08671
3	0.134328358	80	13	13.5	67.5	0.22439
4	0.319148936	44	17	17.5	27.5	0.16891
5	0.319148936	49	22	22.5	27.5	0.02804
6	0.648648649	33	26	26.5	7.5	0.04260
7	0.705882353	38	34	34.5	4.5	0.00276
8	0.769230769	25	24	24.5	1.5	0.00467
9	0.916666667	18	18	18.5	0.5	0.07470
10	0.777777778	10	10	10.5	0.5	0.02316

Genel olarak modellerin kurulumu ve testlerin gerçekleştirildiği araçlar bu şekilde kullanılmış olup, testlerin ve araçların modeller özelinde uygulanması bölümün kalan kısmında belirtilecektir.

3.5.1. XG-Boost Yöntemi

Önceki bölümlerde özelliklerinden bahsedilen XG Boost modelinin SAS üzerindeki kurulumu Şekil 23 da gösterilmektedir. Buna göre model, veri setinde belirtilen bağımsız değişkenler aracılığıyla kurulmuş olup yine önceki bölümlerde belirtilen aralıklar ile sınıflara ayrılmıştır.

Şekil 23 : XGBoost Modeli Kurulumu - SAS

```
1
2 PROC TREEBOOST DATA=inp.bankloans
3   CATEGORICALBINS=10
4   INTERVALBINS=10
5   EXHAUSTIVE=8000
6   INTERVALDECIMALS=MAX
7   LEAFSIZE=5
8   MAXBRANCHES=2
9   ITERATIONS=100
10  MINCATSIZE=20
11  MISSING=USEINSEARCH
12  SEED=13022018
13  SHRINKAGE=0.15
14  TRAINPROPORTION =0.9
15 ;
16 INPUT age ed employ address income debtinc creddebt othdebt / LEVEL=INTE
17 TARGET default / LEVEL=BINARY;
18 SUBSERIES BEST;
19 /* ASSESS VALIDATA=DATA_VALIDATION;
20 CODE FILE="/SGF/GBM.SAS" NOPREDICTION; */
21 SAVE MODEL=GBM IMPORTANCE=IMPORTANCE;
22 RUN;
23
24
25 PROC TREEBOOST INMODEL=GBM;
26 SCORE DATA=inp.bankloans OUT=xgboost PREDICTION;
27 RUN;
28
29
30
31 proc sql;
32 create table XGBoost_Pools as
33 select *,
34 case
35 when P_default1 >=0 and P_default1<0.1 then 1
36 when P_default1 >=0.1 and P_default1<0.2 then 2
37 when P_default1 >=0.2 and P_default1<0.3 then 3
38 when P_default1 >=0.3 and P_default1<0.4 then 4
39 when P_default1 >=0.4 and P_default1<0.5 then 5
40 when P_default1 >=0.5 and P_default1<0.6 then 6
41 when P_default1 >=0.6 and P_default1<0.7 then 7
42 when P_default1 >=0.7 and P_default1<0.8 then 8
43 when P_default1 >=0.8 and P_default1<0.9 then 9
44 when P_default1 >=0.9 and P_default1<1 then 10
45 end as Pool
46 from work.xgboost;
47 run;
```

3.5.1.1. Ayırıştırıcı Güç

Modelin temerrüt ile temerrüt olmayan müşterileri ne derecede ayırt edebildiği önceki bölümlerde bahsedilen Alanın Altında Kalan Alan (AUC) SAS programında hesaplanmıştır. Bölümün başında bahsedilen ve Şekil 19’de gösterilen AUC hesaplama makrosunun XGBoost modeli için uygulaması Şekil 24’da görülebilmektedir.

Şekil 24 : XGBoost AUC hesaplama – Makronun Uygulanması

```
100
101
102 %let var_list =
103 age
104 ed
105 employ
106 address
107 income
108 debtinc
109 creddebt
110 othdebt
111 ;
112
113 /* Bağımsız değişkenler GAUC değerleri */
114 %cstat(varlist=&var_list, inlib=out, dataset = xgboost_final , outname=auc_xgboost_drivers, segm_var=var_
115 , outlib=out , target=default);
116
117
118
119 /* Genel model GAUC değeri */
120 %cstat(varlist=P_default1, inlib=out, dataset = xgboost_final , outname=auc_xgboost_final, segm_var=var_g
121 , outlib=out , target=default);
122
123
```

Kurulan modelin AUC değeri **0,934** olarak hesaplanmıştır. Bu değer modelin oldukça yüksek bir tahminleme gücünün olduğunu göstermektedir. XGBoost modelleri önceki bölümlerde de bahsedildiği üzere birden çok modelin birleşmesinden oluştuğu için bu derece yüksek bir ayırt etme gücünün çıkması beklenen bir sonuç olmuştur.

3.5.1.2. Tahminleme Gücü

Modelin sınıflarının tahminleme gücünün Jeffrey Testi ile ölçüm sonucu Tablo 7 da görülebilmektedir. Sonuca göre 5,6,7 ve 8 inci sınıflar için p-değerlerinin yüzde 5 in altında olduğu görülmektedir. Tekrardan hatırlatmak gerekilirse, p-değeri H0 hipotezinin doğru olduğu halde reddedilme ihtimalini göstermektedir, bir diğer deyişle bu değer küçük olduğunda H0’ı doğru olduğu halde reddetme ihtimali de düşük olacağından H0 hipotezi seçilen sınıra göre (güven düzeyine göre) reddedilebilmektedir. Jeffrey testinde ise sıfır hipotezi hesaplanan uzun dönem TO’sunun gözlemlenen TO dan büyük veya eşit olduğundan 5,6,7 ve 8. Sınıflar için

bu hipotez reddedilmektedir, bir diğer deyişle belirtilen sınıflar için hesaplanan uzun dönem TO hesaplamaları yeterince konservatif değildir.

Tablo 7 : XGBoost Jeffrey Test Sonucu

Sınıf	Hesaplanan TO	Müşteri Sayısı	Temerrüte Düsen Müşteri Sayısı	Alfa	Beta	P-Değeri
1	0,010781671	391	6	6,5	385,5	0,18461
2	0,055172414	162	13	13,5	149,5	0,08671
3	0,134328358	80	13	13,5	67,5	0,22439
4	0,319148936	44	17	17,5	27,5	0,16891
5	0,319148936	49	22	22,5	27,5	0,02804
6	0,648648649	33	26	26,5	7,5	0,04260
7	0,705882353	38	34	34,5	4,5	0,00276
8	0,769230769	25	24	24,5	1,5	0,00467
9	0,916666667	18	18	18,5	0,5	0,07470
10	0,777777778	10	10	10,5	0,5	0,02316

Jeffrey testinin sonucu olarak toplam 10 sınıftan 6 sınıfın p-değeri 0.05 in üzerinde çıkmıştır, bir diğer deyişle diğer modellerin sonuçlarıyla karşılaştırılacak isabetlilik oranı **0,6**'dır.

3.5.1.3. Yoğunluk

Modelin sınıflarında bulunan müşteri sayılarının ne derece homojen dağıldığını ölçmek için kullanılan Herfindahl Endeksi (HI) Şekil 21'de gösterilen Excel yardımıyla hesaplanmıştır. Buna göre modelin HI değeri **0,427** olarak hesaplanmaktadır.

3.5.2. Rassal Orman Modeli

Önceki bölümlerde özelliklerinden bahsedilen Rassal Orman (Random Forest) modelinin Python üzerindeki kurulumu Ek5'te gösterilmektedir. Buna göre model, veri setinde belirtilen bağımsız değişkenler aracılığıyla kurulmuş olup yine önceki bölümlerde belirtilen aralıklar ile sınıflara ayrılmıştır.

3.5.2.1. Ayırıştırıcı Güç

Modelin ayırıştırıcı gücünü ölçmek için kullanılan AUC değerinin hesaplanması Şekil 19'de gösterilen SAS makrosu yardımıyla yapılmıştır. Modelin

AUC değeri **0.882** olarak hesaplanmaktadır. Bu değerin modelin güçlü bir ayrıştırma gücüne sahip olduğunu göstermektedir. Çoklu makine öğrenme yöntemlerinden biri olan Rassal Orman algoritmasında yüksek performans beklenene bir şey olup yine de bir benzer algoritma olan XGBoost algoritmasının altında kaldığı görülebilmektedir.

3.5.2.2. Tahminleme Gücü

Rassal Orman modeli için uygulanan Jeffrey Testi'nin sonuçları aşağıdaki tabloda görülmektedir.

Tablo 8 : Rassal Orman Jeffrey Testi Sonucu

Sınıf	Hesaplanan TO	Müşteri Sayısı	Temerrüte Düsen Müşteri Sayısı	Alfa	Beta	P-Değeri
1	0,192156863	510	98	98,5	412,5	0,49539
2	0,184	125	23	23,5	102,5	0,49024
3	0,225806452	31	7	7,5	24,5	0,48402
4	0	1	0	0,5	1,5	0,00000
5	0	0	0	0,5	0,5	0,00000
6	0	0	0	0,5	0,5	0,00000
7	0,125	24	3	3,5	21,5	0,46799
8	0,329268293	82	27	27,5	55,5	0,49463
9	0,31884058	69	22	22,5	47,5	0,49373
10	0,428571429	7	3	3,5	4,5	0,49232

Buna göre içinde müşteri bulunan her grup için p değerinin 0.05'den büyük olduğu görülmektedir. Bir diğer deyişle bütün sınıflar için sıfır hipotezini reddetmek için yeterli kanıt bulunamamaktadır. Dolayısıyla hesaplanan uzun dönem TO hesaplamaları gerçekleşen TO'lardan büyük veya eşittir.

3.5.2.3. Yoğunluk

Rassal Orman için hesaplanan Herfindahl Endeksi **0,602** olarak belirlenmiştir. Bu değer modelleri içerisinde en yüksek HI değeridir.

3.5.3. Destek Vektör Sınıflandırması Yöntemi

Karşılaştırılacak olan modellerden bir diğeri olan destek vektör sınıflandırma algoritmasının SAS üzerinden kurulumu Şekil 25'de görülmektedir. Modelde çekirdek

fonksiyon olarak iki dereceli polinomal fonksiyon kullanılmıştır. Model kurulduktan sonra skorlanan kayıtlar daha sonra belirtilen şekilde sınıflara ayrılmışlardır.

Şekil 25 : Destek Vektör Sınıflandırma Algoritması SAS kurulumu

```
1 proc hpsvm data=inp.bankloans;
2 input age ed employ address income debtinc creddebt othdebt/level=interv
3 kernel polynom / degree=2;
4 target default;
5 output outclass=outclass outfit=outfit outest=outest ;
6 run;
7
8
9 proc svm score data=inp.bankloans out=score_svm
10 inclass=outclass infit=outfit inest=outest;
11 run;
12
13
14 data work.svm;
15 set work.data7;
16 musteri_no=_n_;
17 run;
18
19 proc sql;
20 create table out.svm_final as
21 select *,
22 1 as var_group,
23 case when Default_Probabilty >=0.5 then 1 else 0 end as Predicted_Default
24 default as observed_default_flag,
25 case
26 when Default_Probabilty >=0 and Default_Probabilty<0.1 then 1
27 when Default_Probabilty >=0.1 and Default_Probabilty<0.2 then 2
28 when Default_Probabilty >=0.2 and Default_Probabilty<0.3 then 3
29 when Default_Probabilty >=0.3 and Default_Probabilty<0.4 then 4
30 when Default_Probabilty >=0.4 and Default_Probabilty<0.5 then 5
31 when Default_Probabilty >=0.5 and Default_Probabilty<0.6 then 6
32 when Default_Probabilty >=0.6 and Default_Probabilty<0.7 then 7
33 when Default_Probabilty >=0.7 and Default_Probabilty<0.8 then 8
34 when Default_Probabilty >=0.8 and Default_Probabilty<0.9 then 9
35 when Default_Probabilty >=0.9 and Default_Probabilty<=1 then 10
36 end as Pool
37 from out.svm_final;
38 run;
39
```

3.5.3.1. Ayırıştırıcı Güç

Modelin ayırıştırıcı gücü önceki bölümde bahsedilen SAS makrosu yardımıyla hesaplanmış olup, değeri **0.835** olarak bulunmuştur. Bu değer modelin nispeten iyi bir ayırıştırıcı gücü olduğunu gösterse bile bütün modeller içinde en düşük ayırıştırıcı güce olduğunu da belirtmek gerekir.

3.5.3.2. Tahminleme Gücü

Modelin çıktılarının sınıflandırılmasından sonra gerçekleştirilen her bir modelin tahminleme gücü Jeffrey Testi ile ölçülmüştür. Jeffrey Testinin sonucu Tablo 9'de görülebilmektedir.

Tablo 9 : Destek Vektör Sınıflandırması Jeffrey Testi Sonucu

Sınıf	Hesaplanan TO	Müşteri Sayısı	Temerrüte Düsen Müşteri Sayısı	Alfa	Beta	P-Değeri
1	0	9	0	0,5	9,5	0,00000
2	0	92	0	0,5	92,5	0,00000
3	0,074585635	362	27	27,5	335,5	0,48863
4	0,318996416	279	89	89,5	190,5	0,49690
5	0,539473684	76	41	41,5	35,5	0,50122
6	0,7	17	15	15,5	2,5	0,04124
7	0,75	10	7	7,5	3,5	0,66165
8	0,882352941	4	3	3,5	1,5	0,81707
9	0	0	0	0,5	0,5	0,00000
10	0	0	0	0,5	0,5	0,00000

Buna göre veri kümesindeki kayıt sayısının azlığı ve sınıflandırma algoritmasının basitliğinden ötürü boş kalan sınıflar hesaba katılmadığında diğer 6 sınıftan 5 inin p değerinin 0.05 den büyük olduğu görülmüştür. Ancak altıncı sınıf için p değeri 0.05 den küçük olup, bu sonuç altıncı sınıf için tahmin edilen TO değerinin yeterince konservatif olmadığını göstermektedir. Jeffrey testinin sonucu olarak içinde müşteri bulunan toplam 6 sınıftan 5 inin p-değeri 0.05 in üzerinde çıkmıştır, bir diğer deyişle diğer modellerin sonuçlarıyla karşılaştırılacak isabetlilik oranı 0.833'dür


3.5.3.3. Yoğunluk

Modelin çıktılarının sınıflara dağıtılması sonucu her bir sınıftaki müşteri sayısı ile hesaplanan HI değeri, **0,491** olarak ölçülmüştür.

3.5.4 Lojistik Regresyon Modeli

Mevcut kullanılan yöntem olan Lojistik Regresyon algoritması, SAS programında Şekil 26'de görüldüğü üzere geliştirilmiştir.

Şekil 26 : Lojistik Regresyon – SAS Model Kurulumu



```
1 %let var_list =
2 age
3 ed
4 employ
5 address
6 income
7 debtinc
8 creddebt
9 othdebt
10 ;
11
12 %let v_noint = ;
13
14 proc logistic data=inp.bankloans outest=out.model_params covout PLOTS(maxpoints=none);
15
16     model default=
17
18         %Var_list.
19
20     / selection=none
21       slentry=0.01
22       slstay=0.001
23       details
24       lackfit
25       rsquare
26       %v_noint.
27     ;
28     roc;
29
30     output out=pred p=phat lower=lcl upper=ucl
31           predprob=(individual crossvalidate);
32     store logistic_model;
33 run;
34 ODS GRAPHICS OFF;
35
36
37 proc plm restore=logistic_model;
38   score data=inp.bankloans out=out.logistic_final predicted=Default_Probability / ilink;
39 run;
40
41
42
```

Description	Lin	Affecte	Log I	Prog
1	1			
2	2			
3	1			
4	2			
5	3			
6	4			
7	5			
8	6			
9	7			
10	8			
11	9			
12	10			
13	11			
14	12			
15	13			
16	14			
17	15			
18	16			
19	17			
20	18			
21	19			
22	20			
23	21			
24	22			
25	23			
26	24			
27	25			
28	26			
29	27			
30	28			

Modelde diğer modeller ile uyum sağlamak adına herhangi bir değişken seçimi yapılmamıştır.

3.5.4.1. Ayırıştırıcı Güç

Lojistik Regresyon modelinin AUC değeri **0.841** olarak hesaplanmıştır. Bu değer modelin ayırıştırıcı gücünün kötü olmadığını gösterse de diğer daha kompleks makine öğrenmesi modellerine (örneğin XGBoost) kıyasla daha geride bir değerdir.

3.5.4.2. Tahminleme Gücü

Lojistik Regresyon modelinin çıktılarını belirtilen kurala göre sınıflara ayırdıktan sonra gerçekleştirilen Jeffrey Testinin sonuçları Tablo 10'da görülebilmektedir.

Tablo 10 : Lojistik Regresyon – Jeffrey Testi Sonuçları

Sınıf	Hesaplanan TO	Müşteri Sayısı	Temerrüte Düşen Müşteri Sayısı	Alfa	Beta	P-Değeri
1	0,625	8	5	5,5	3,5	0,51280
2	0,6667	9	6	6,5	3,5	0,51656
3	0,7058	17	12	12,5	5,5	0,51471
4	0,668	21	14	14,5	7,5	0,51574
5	0,6511	43	28	28,5	15,5	0,50616
6	0,48	50	24	24,5	26,5	0,49924
7	0,395	81	32	32,5	49,5	0,49636
8	0,2479	121	30	30,5	91,5	0,49256
9	0,1151	165	19	19,5	146,5	0,48661
10	0,0388	335	13	13,5	322,5	0,48227

Jeffrey Testi çıktısına göre modelin bütün sınıfları için p-değeri 0.05 den büyük olup, bütün sınıflar için tahmin edilen TO değerinin gerçekleşen TO değerine göre daha konservatif olduğu sonucuna erişilebilir.

3.5.4.3. Yoğunluk

Lojistik regresyon modelinin çıktılarının sınıflara dağılımından hesaplanan HI değeri **0,360** olarak hesaplanmaktadır. Bu değer modelin çıktılarının diğer modellere göre daha eşit bir dağılım gösterdiğini belirtmektedir.

3.6. MODELLERİN KARŞILAŞTIRILMASI

Yapılan çalışmada önceki bölümde bahsedildiği üzere Lojistik Regresyon, XGBoost, Rassal Orman ve Destek Vektör Sınıflandırması modelleri kurulup modeller belirli metotlar aracılığıyla belirli kriterler ile birbirleriyle nicel olarak karşılaştırılmışlardır. Yapılan karşılaştırma sayısal olarak ifade etmek gerekirse her bir model kriterlere göre önceki bölümlerde bahsedildiği üzere puanlanmıştır. Daha sonradan modellerin her bir bölümde aldığı puan kriterler bölümünde bahsedildiği üzere bir çarpan ile çarpılıp toplam puan hesaplamasında kullanılmıştır. Tablo 11 modellerin Ayırıştırıcı güç kriterine göre değerlerini ve puanlarını içermektedir. Buna göre AUC değeri en yüksek çıkan XGBoost modeli 4 puan almış ve Ayırıştırıcı güç

kriterinin önem derecesi diğer kriterlere göre daha fazla olduğundan toplam model puanına 2 ile çarpılarak eklenmiştir.

Tablo 11 : Ayırıştırıcı Güç Karşılaştırması – Özet Tablo

Model / Test	AUC	AUC Sıralama	AUC Puan	AUC - Toplam Model Puanı (X 2)
Lojistik Regresyon	0.841	3	2	4
XGBoost	0.934	1	4	8
Rassal Orman	0.882	2	3	6
Destek Vektör Sınıflandırması	0.835	4	1	2

Yüksek ayırıştırıcı güç çoklu makine öğrenmesi algoritmalarında beklenen bir özellik olup aynı şekilde modellerin nitel karşılaştırmalarında da bahsedilmiştir. Modellerin nicel sonuçları da teorideki nitel özelliklere uygun olarak gerçekleşmiştir, öyle ki çoklu makine öğrenmesi algoritmaları olan XGBoost ve Rassal Orman algoritmaları en yüksek ayırıştırıcı güce sahip olan algoritmalar olarak öne çıkmıştır. Mevcut uygulama olan Lojistik regresyon algoritması ayırıştırıcı güç bakımından bu modellerin gerisinde kalmaktadır. Daha basit ve sade bir model Lojistik regresyon modeli yine bu özelliklerinden ötürü sektörde daha çok tercih edilmektedir. Öte yandan Destek Vektör Sınıflandırması algoritması ayırıştırıcı güç açısından en zayıf model olarak gözükmektedir.

Bir diğer kriter olan Tahminleme gücü açısından modeller sınıflar bazında Jeffrey Testine tabi tutulmuştur. Her bir modele ait her bir sınıfın tahmin edilebilirlik ve konservatiflikleri bu test ile sınanmıştır. Veri setinin yeterince büyük olmaması ve sınıflara ayırma metodunun oldukça basit olması sebebiyle bazı modellerde bazı sınıfların boş kaldığı görülüp sınıflara ait Uzun Dönem Ortalamalarının (LRA) monotonik bir şekilde artmadığı görülmüştür. Boş kalan sınıflar Jeffrey testinin değerlendirmesinden çıkartıldığında modellere ait sınıfların kaçının testten geçtiği kullanılarak oluşturulan karşılaştırma aşağıdaki tabloda görülebilmektedir.

Tablo 12 : Jeffrey Testi Karşılaştırması – Özet Tablo

Model / Test	Jeffrey Test	Jeffrey Testi Sıralama	Jeffrey Test Puan	Jeffrey Test - Toplam Model Puanı
Lojistik Regresyon	1	1	4	4
XGBoost	0.6	4	1	1
Rassal Orman	1	1	4	4
Destek Vektör Sınıflandırması	0.833	3	2	2

Çıkan sonuç tablosuna göre XGBoost modelinin ayrıştırıcı gücü en yüksek model olsa da tahminleme gücü açısından 4 sınıfta yeterince tutucu – konservatif olmadığı görülebilmektedir. Önceden de bahsedildiği gibi veri kümesinin yeterince büyük olmamasının ve bunun sonucu olarak sınıflarda çok sayıda müşteri bulunmamasının da bunda etkisi olmaktadır. Ancak genel sonuca bakıldığında Rassal Orman ve Lojistik Regresyon algoritmalarının bütün sınıflar için yeterince iyi tahminleme gücüne sahip oldukları görülebilmektedir. Bu sebepten her ikisi de birinci puanı olan 4 puan almıştır. Destek Vektör Sınıflandırması ise ikinci en yüksek olmasına rağmen iki tane yüzde yüzlük sınıf isabeti olan algoritma olduğu için üçüncü puanı bir diğer deyişle 2 puan almıştır. Tahminleme gücünün toplam modele yansımaları 1 ile çarpıldığından olduğu gibi yansımaktadır.

Modellerin sınıflara dağılmasından sonra yoğunluklarının karşılaştırıldığı HI değerinin modeller özeti ve puanlaması aşağıdaki tabloda görülebilmektedir. Önceki bölümlerde de belirtildiği üzere bu kriterin çarpanı 0,5 olarak belirlenmiştir.

Tablo 13 : Herfindahl Endeksi Özet Tablo

Model / Test	Herfindahl Endeksi	Herfindahl Endeksi Sıralama	Herfindahl Endeksi Puan	Herfindahl Endeksi - Toplam Model Puanı
Lojistik Regresyon	0,360	1	4	2
XGBoost	0,427	2	3	1.5
Rassal Orman	0,602	4	1	0.5
Destek Vektör Sınıflandırması	0,491	3	2	1

Buna göre, veri kümesindeki kayıtların skorlanıp sınıflara dağıtılmasında en eşit şekilde skorlayan model Lojistik regresyon modeli olduğu görülmektedir. Kriterlerin bahsedildiği bölümde de bahsedildiği üzere sınıfların yoğunluğunun

modellerin çıktılarıyla ilişkisi olduğu kadar sınıflamanın nasıl yapıldığıyla da ilişkisi bulunmaktadır. Bu yüzden sınıflamanın sonucunu yalnızca modelin performansına bağlamak yanlış olacağından bu kriterin çarpanı 0.5 olarak belirlenmiştir. Çıkan sonuca göre Destek Vektör Sınıflandırması algoritması çıktıları en eşit olmayan şekilde sınıflara dağıtan algoritma olarak öne çıkmaktadır.

Sektörde kullanılan Lojistik Regresyon dahil diğer 3 algoritmanın nicel sonuçları yukarıda bahsedildiği üzere belirlenmiştir. Her üç kriterin sonucuna göre oluşan toplam puanlar Tablo 14’de görülebilmektedir.

Tablo 14 : Nicel Araştırma Final Puanları

Model / Test	Toplam Puan
Lojistik Regresyon	10
XGBoost	10,5
Rassal Orman	10,5
Destek Vektör Sınıflandırması	5

Modellerin nicel olarak karşılaştırılmalarına göre Çoklu Makine Öğrenmesi algoritmaları olan XGBoost ve Rassal Ormanın mevcut Lojistik Regresyon algoritmasına göre bir adım daha önde olduğu görülebilmektedir. Her iki model de önceden bahsedildiği üzere birden çok makine öğrenmesi algoritması (karar ağacı) içeren çok daha komplike modeller olup çıktı performansı olarak daha iyi sonuçlar vermesi beklenen algoritmalar idi. Bu beklentinin de nicel araştırma sonucuna yansıdığı görülebilmektedir. Öte yandan çoklu makine öğrenmesi algoritması olmayan Destek Vektör Sınıflandırma algoritmasının ise çıktı performansı olarak yeteri kadar iyi sonuç vermediği nicel araştırma sonucunda görülebilmektedir. Nicel araştırma sonucunda XGBoost veya Rassal Orman algoritmalarının mevcutta kullanılan Lojistik Regresyon modeline göre daha tercih edilebilir olduğu sonucuna varılmıştır.

SONUÇ

Çalışmada IDD TO modellerinde mevcut kullanılan yöntem olan Lojistik Regresyon yöntemi ile 3 farklı makine öğrenmesi algoritması çıktı analizleri yapılarak ve IDD TO modellerine uygulanabilirliği araştırılarak karşılaştırılmıştır.

Nicel analizin sonucunda 4 farklı modelin çıktıları karşılaştırılınca çoklu makine öğrenmesi modelleri olan XGBoost ve Rassal Orman modellerinin, sektörde daha çok kullanılan model olan Lojistik Regresyon ve diğer alternatif olan Destek Vektör Sınıflandırması modellerinden daha iyi performans sergilediği sonucu çıkartılmıştır. Her iki model de ayrıştırma gücü bakımından Lojistik regresyon modelinden daha iyi performans sergilemektedir. Toplam sonuca bakıldığında da yine bu iki modelin daha yüksek puan aldığı ve nicel olarak incelendiğinde alternatif makine öğrenmesi algoritmalarından XGBoost ve Rassal Orman modellerinin mevcut kullanılan Lojistik regresyon modeline göre daha uygun olduğu sonucu çıkartılmıştır.

Araştırmanın ikinci kısmında ise modellerin güçlü ve zayıf yönleri karşılaştırılmıştır, modellerin bu özelliklerinin IDD TO modelleri doğasına olan uygunluğu ve uyumu araştırılmıştır. Lojistik Regresyon modelinin yıllardır bankaların genelinde mevcut olarak kullanılmasının en büyük sebebi olarak modelin basit ve yorumlanabilir olması olduğu belirtilmiştir. Bu açıdan bakıldığında nicel araştırma sonucunda öne çıkan XGBoost ve Rassal Orman modelleri, Lojistik regresyon modeli ile kıyaslanmıştır. Rassal Orman modeli içinde bulunan çok sayıda karar ağacının paralel olarak karar vermesinden oluşan sonucu kullandığından ötürü kara kutu modeli olarak nitelendirilmektedir. Bu özelliği ile modelin çıktısını ilgili kişilere veya denetleyici kurumlara anlatması ve sonuç çıkartılamayacağı söylenebilir. Bu açıdan Rassal Orman algoritmasının daha iyi sonuç vermesine rağmen IDD TO modeli olarak ilk sırada tercih edilecek bir algoritma olmayacağı sonucu çıkartılmıştır. Nicel olarak daha iyi performans gösteren bir diğer alternatif olan XGBoost modeli ise Lojistik regresyon kadar basit yorumlanamasa bile Python gibi dillerde gelişen teknoloji ile ortaya çıkan yeni performans paketleri sayesinde görselleştirme ve değişken önemi karşılaştırma gibi özellikler ile yine makul seviyede yorumlanabilir seviyeye gelmiştir. Araştırma sonucunda, Lojistik Regresyonun en önemli özelliği olan yorumlanabilirlik özelliği için vazgeçilen ‘önemli ölçüde çıktı performansı’- bankaların da iştahına bağlı

olarak deęişse de – mantıklı ve faydalı bir seviyede olmadığı sonucu çıkartılmıştır. Çalışmanın sonucunda alternatif makine öğrenmesi algoritmalarından XGBoost’un mevcut yöntem olan Lojistik Regresyon yöntemine kıyasla tercih edilebileceęi sonucuna varılmıştır. Bankaların da bu bağlamda IDD TO modelleri kurarken alternatif makine öğrenmesi modellerini denemeleri onlar adına daha isabetli tahminler yapmalarını sağlayacaktır.

Özellikle son yıllarda veri bilimi ve yapay zeka gibi alanlarda gerçekleşen hızlı ve büyük gelişmelerden sonra makine öğrenmesi modellerine ait her türlü düzenleme ve ek paket programları ile algoritmaların yorumlanabilirlik açıkları kapatılmakta olup modeller ve çıktıları biraz bilgisi olan herkesin anlayabileceęi noktalara gelmektedir. Özellikle ECB, EBA gibi denetim ve kontrol otoritelerinin teknolojik olarak veri bilimi alanında yapılan yenilik ve gelişmeleri ihtiyatlı bir şekilde geriden gelerek takip etmeleri bu kaçınılmaz dönüşüme bir gecikme olarak yansısı da yıllar sonra Kasım 2021’de EBA tarafından dağıtılan ‘IDD Modelleri için Makine Öğrenmesi Yöntemlerinin Kullanımı’¹³¹ isimli tartışma kağıdı artık denetleyici ve kural koyucu kurumların da daha güncel algoritmalar kullanma isteęi olduğunu ve bankacılığın ve IDD modellerinin Makine öğrenmesi algoritmalarına doğru hızlıca gittiğini göstermektedir. Araştırmanın neticesinde de bu doğrultuda bir sonuca varılmış olup, yakın gelecekte olası bir IDD TO modellerine geçiş kararı yine bu tarz araştırmaların sonuçlarına dayandırılarak alınacaktır.

¹³¹ European Banking Authority. (2021, Kasım 11). Discussion paper on machine learning for İRB Models. (Çevrimiçi), Aralık 14, 2021.

Kaynakça

- Altman E.I. : Default recovery rates and LGD in credit risk modelling and Practice. Economic Notes 33(2), 2011, ss. 183-208.
- Amidi, A. (Çevrimiçi) Gözetimli öğrenme El Kitabı. CS 229 - Gözetimli Öğrenme El Kitabı. Ağustos 28, 2021.
- Arestis P. Main and Contributory Causes of the Recent Financial Crisis and Economic Policy Implications. Emerging economies during and after the Great Recession (1st ed.). Palgrave Macmillan UK :Imprint: Palgrave Macmillan., (2016), ss. 1-36.
- Arslan, İ. BASEL KRİTERLERİVE TÜRK BANKACILIK SEKTÖRÜNE ETKİLERİ . Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi , 2007, (18) , ss. 49-66 .
- Ashanira D., Azlan M., Roselina S., Overview of Support Vector Machine in Modeling Machining Performances, Procedia Engineering, Volume 24, 2011, ss. 308-312.
- BABUŞÇU, Ş., “Bankalarda Risk Derecelendirmesi (Rating) ve Türk Bankacılık Sektörü’ne Uygulanması”, SPK Yayınları, (1997), Sayı:4.
- Balthazar L. Basel 1 to Basel 3. In: Basel 1 to Basel 3: The Integration of State-of-the-Art Risk Modeling in Banking Regulation. Finance and Capital Markets Series. Palgrave Macmillan, London. (2006) ss. 87-92.

Bankacılık Düzenleme ve Denetleme Kurumu,

(Çevrimiçi), 10 Soruda Yeni Basel Sermaye Uzlaşısı (Basel II), https://www.bddk.org.tr/ContentBddk/dokuman/duyuru_basel_0001_38.pdf Ekim 2009.

Bankacılık Düzenleme ve Denetleme Kurumu:

TFRS 9 Uyarınca Beklenen Kredi Zarar Karşılığı Hesaplamasına İlişkin Rehber, 2018, s. 14.

Basel Committee On Banking Supervision

(Çevrimiçi), International Organization Of Securities Commissions International Association Of Insurance Supervisors. <https://www.bis.org/publ/joint03.pdf> 1999, Aralık.

Basel Committee on Banking Supervision.:

(Çevrimiçi) An Explanatory Note on the Basel II IRB Risk Weight Functions <https://www.bis.org/bcbs/irbriskweight.htm> .

Bank of International Settlements :

(Çevrimiçi), "Basel III: The Liquidity Coverage Ratio And Liquidity Risk Monitoring Tools". <https://www.bis.org/publ/bcbs238.htm> 2013.

Bank of International Settlements :

(Çevrimiçi) "Basel III: The Net Stable Funding Ratio". <https://www.bis.org/bcbs/publ/d295.htm> 2014.

Bank of International Settlements :

(Çevrimiçi), "Revisions To Leverage Ratio Disclosure Requirements". <https://www.bis.org/bcbs/publ/d456.htm> 2019.

Bank of International Settlements :

(Çevrimiçi), Cre - calculation of rwa for credit risk. The Bank for International Settlements. https://www.bis.org/basel_framework/chapter/CRE/20.htm Eylül 2021.

Blochwitz, S., Martin, M. R., & Wehn, C. S. :

Statistical approaches to PD validation. The Basel II Risk Parameters, Basılı, ss. 289–306.

- Blöchwitz, S. : Validation of Banks' internal rating systems: A challenging task? The Journal of Risk Model Validation, 1(4), (2008), ss. 3–16.
- Capeci, J. : Credit risk, credit ratings, and municipal bond yields: A panel study. National Tax Journal, 44(4.1), (1991), ss. 41–56.
- Caselli, S., S. Gatti, and F. Querci : The Sensitivity of the Loss Given Default Rate to Systematic Risk: New Empirical Evidence on Bank Loans. Journal of Financial Services Research 34(1), ss. 1–34.
- Cossin, D., & Hricko, T. (2003). A structural analysis of credit risk with risky collateral: A methodology for haircut determination. Economic Notes, 32(2), (2008) ss. 243–282.
- Deloitte (Çevrimiçi), United States, Basel III to "Basel IV": What changed?: <https://www2.deloitte.com/mm/en/pages/risk/articles/basel-iii-to-basel-iv.html> (2018).
- Draper, T. Regulation of capital adequacy in Western European banking through the Internal Capital Adequacy Assessment Process (ICAAP) & the Supervisory Review & Evaluation Process (Srep). CRIS - Bulletin of the Centre for Research and Interdisciplinary Study, 2014(2) ss. 29-49.
- Engelmann, B., & Rauhmeier, R. The basel II risk parameters estimation, validation, stress testing - with applications to loan risk management (2nd ed.). 2014, Springer Berlin.

European Banking Authority. :	(Çevrimiçi),Eba report on İRB modelling practices. https://www.eba.europa.eu/sites/default/documents/files/documents/10180/1720738/0212ecde-426d-4e18-84f8-04b036dcce00/EBA%20Report%20on%20IRB%20modelling%20practices.pdf?retry=1 (2017).
European Banking Authority. :	(Çevrimiçi). Estimation of credit conversion factor in case of exposure values decreasing before default event https://www.eba.europa.eu/single-rule-book-qa/-/qna/view/publicId/2019_4883 (2021).
European Banking Authority. :	(Çevrimiçi).Discussion paper on machine learning for İRB Models. https://www.eba.europa.eu/regulation-and-policy/model-validation/discussion-paper-machine-learning-irb-models Aralık 2021.
European Banking Authority. :	(Çevrimiçi). Final Report Guidelines on the application of the definition of default under Article 178 of Regulation (EU) No 575/2013. https://www.eba.europa.eu/regulation-and-policy/credit-risk/guidelines-on-the-application-of-the-definition-of-default Ağustos 28, 2021.
European Banking Authority.	(Çevrimiçi), Guidelines for the estimation of LGD appropriate for an economic downturn ('Downturn LGD estimation'). https://www.eba.europa.eu/eba-publishes-final-guidelines-on-the-estimation-of-lgd-under-an-economic-downturn Temmuz 17, 2021.
European Central Bank.	(Çevrimiçi).Instructions for reporting the validation results of internal models https://www.bankingsupervision.europa.eu/banking/tasks/internal_models/shared/pdf/instructions_validation_reporting_credit_risk.en.pdf Şubat 2019.
Florian Manz,	"Determinants of non-performing loans: What do we know? A systematic review and avenues for future research," Management Review Quarterly, Springer, 2019, vol. 69(4), ss.351-389.

- Garbade, D. M. J. (Çevrimiçi). Understanding K-means clustering in machine learning. <https://towardsdatascience.com/understanding-k-means-clustering-in-machine-learning> (2018)
- Gatzert, N., Martin, M. Quantifying credit and market risk under solvency II: Standard approach versus internal model. *Econ Papers*. 2012, 51(3), ss.649–666.
- Geithner, T. F. Stress test: reflections on financial crises. First edition. New York: Crown Publishers. 2014. ss. 223-246.
- João Fernandes, "Corporate Credit Risk Modeling: Quantitative Rating System And Probability Of Default Estimation," *Finance* 0505013, 2005, University Library of Munich, Germany.
- Krebs, M., & Nippel, P. Unexpected loss, expected profit, and economic capital: A note on economic capital for credit risk incorporating interest income, expenses, losses, and Roe Target. *Finance Research Letters*, 2013, s. 38.
- KÜLAHI, E. A. TÜRKİYE'DE BASEL I, II ve III KURALLARINA UYUM SÜRECİ. 2013, Cilt 10, Sayı 40, ss. 185 – 200.
- Leippold, M. Testing Probability Calibrations: Application to Credit Scoring Models. Working Paper No. 323 , 2006, Zurich.
- Lopez, Jose A. & Saidenberg, Marc R., "Evaluating credit risk models," *Journal of Banking & Finance*, Elsevier, 2000, vol. 24(1-2), ss. 151-165.

- Lopez, Jose A., "The empirical relationship between average asset correlation, firm probability of default, and asset size," *Journal of Financial Intermediation*, Elsevier, 2004, vol. 13(2), ss. 265-283.
- Mason, Joseph R. & Rosner, Joshua, Where Did the Risk Go? How Misapplied Bond Ratings Cause Mortgage Backed Securities and Collateralized Debt Obligation Market Disruptions ,Mayıs 2007). Print. ss. 33-45.
- Melvin, M., & Taylor, M. P. The global financial crisis: Causes, threats and opportunities. introduction and overview. *Journal of International Money and Finance*, 2009, 28(8), ss. 1243–1245.
- Miu, P., & Ozdemir, B. Estimating and validating long-run probability of default with respect to Basel II requirements. *The Journal of Risk Model Validation*, 2008, 2(2), ss. 3–41.
- Morgan, S. P., & Teachman, J. D. Logistic regression: Description, examples, and comparisons. *Journal of Marriage and the Family*, 1988, 50(4), s. 929.
- Murphy, A. An Analysis of the Financial Crisis of 2008: Causes and Solutions. *Structured Markets Equity Derivatives Journal*. 2008, 7(2), ss. 15-22.
- Nahit Özen, Gelişen Piyasa Koşullarında Krediler ve Kredilendirme Süreci, Türkiye Bankalar Birliği Eğitim Merkezi Seminer Notlari, Şubat 2009.

- Neisen, M. (Çevrimiçi). Observations about the impact of a downturn period on the main components of the LGD Model - PWC Regulatory Blog. <https://blogs.pwc.de/regulatory/credit-decision-risk-modelling/observations-about-the-impact-of-a-downturn-period-on-the-main-components-of-the-lgd-model/4872/>.
- Nielsen, D. Tree Boosting With XGBoost Why Does XGBoost Win "Every" Machine Learning Competition? (tez). Norwegian University of Science and Technology, 2016, Oslo, ss.32-40.
- Novotny-Farkas, Z. The interaction of the IFRS 9 expected loss approach with supervisory rules and implications for Financial Stability. Accounting in Europe, 2016, 13(2), ss. 197–227.
- Peter Gachoki, Moses Mburu, Moses Muraya. Predictive Modelling of Benign and Malignant Tumors Using Binary Logistic, Support Vector Machine and Extreme Gradient Boosting Models. American Journal of Applied Mathematics and Statistics. 2019; 7(6): ss. 196-204.
- Prorokowski, L. Validation of the backtesting process under the targeted review of internal models: Practical recommendations for probability of default models. Journal of Risk Model Validation , 2019, 13(2) ss.109-147.
- Putri, N. H., Fatekurohman, M., & Tirta, İ. M. Credit risk analysis using support vector machines algorithm. Journal of Physics: Conference Series, 2021, 1836(1), 012039.
- PWC. : (Çevrimiçi), IFRS 9 understanding the basics - PWC: Audit and assurance <https://www.pwc.com/gx/en/audit-services/ifrs/publications/ifrs-9/ifrs-9-understanding-the-basics.pdf> Kasım 2021.
- Rauhmeier, R. PD-validation: Experience banking practice. The Basel II Risk Parameters, 2011, ss. 311–347.

Reddy, K. S., Nangia, V. K., & Agrawal, R.

The 2007–2008 Global Financial Crisis, and Cross-border Mergers and Acquisitions: A 26-nation Exploratory Study. *Global Journal of Emerging Market Economies*, 2014, 6(3), ss. 257–281.

Schenider S,

(Çevrimiçi), Basel “IV”: What’s next for banks? Implications of intermediate results of new regulatory rules for European banks. Basel “IV”: What’s next for banks? <https://www.mckinsey.com/~media/mckinsey/business%20functions/risk/our%20insights/basel%20iv%20whats%20next%20for%20european%20banks/basel-iv-whats-next-for-banks.ashx>. (2017, Nisan).

Stoltzfus, J. C.

Logistic regression: A brief primer. *Academic Emergency Medicine*, 2011, 18(10), ss. 1099–1104.

Tasche, D.

A traffic lights approach to PD validation, 2003, Working Paper, Deutsche Bundesbank.

TBB, Türkiye Bankalar Birliği.

Bankaların Sermaye Yeterliliğinin Ölçülmesine Ve Değerlendirilmesine İlişkin Yönetmelik. 2011, İstanbul, Resmi Gazete: TBB.

The Bank for International Settlements.

(Çevrimiçi) Studies on the validation of Internal Rating Systems (revised). https://www.bis.org/publ/bcbs_wp14.htm Mayıs 2005.

The Bank for International Settlements.

(Çevrimiçi), Prudential treatment of problem assets - definitions of non-performing exposures and forbearance. <https://www.bis.org/bcbs/publ/d403.htm>

Tu, J. V.

Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. *Journal of Clinical Epidemiology*, 1996, 49(11), ss. 1225–1231.

Uanhoro, J. O., Wang, Y.,
& O'Connell, A. A.

Problems with using odds ratios as effect sizes in binary logistic regression and alternative approaches. *The Journal of Experimental Education*, 2019, 89(4), ss. 670–689.

Uddin, M. S., Chi, G., Al
Janabi, M. A., & Habib, T.

Leveraging Random Forest in micro-enterprises credit risk modelling for accuracy and interpretability. *International Journal of Finance & Economics*, 2020, 5-(2) ss. 3-14.

Vasicek, O.

The Distribution of Loan portfolio value risk, 2002, Vol. 15, No. 3, ss. 26-32.

Wiesmeier, M., Barthold,
F., Blank, B., & Kögel-
Knabner, I.

Digital mapping of soil organic matter stocks using random forest modeling in a semi-arid steppe ecosystem. *Plant and Soil*, 2010, 340(1-2), ss. 7–24.

Yaman, A. & Cengiz, M.
A.

The Effects of Kernel Functions and Optimal Hyperparameter Selection on Support Vector Machines . *Journal of New Theory* , 2021, (34), ss. 64-71 .

Ekler

Ek 1 Risk Ağırlıkları Hesaplamaları

Varlık Sınıfı	Kurumsal Riskler		Konut Kredileri		Diğer Bireysel Krediler		Bireysel Rotatif Krediler	
THK:	45%	45%	45%	25%	45%	85%	45%	85%
Ciro (Milyon Euro):	50	5						
Vade	2.5 Yıl	2.5 Yıl						
TO :								
0.03%	14.44%	11.30%	4.15%	2.30%	4.45%	8.41%	0.98%	1.85%
0.05%	19.65%	15.39%	6.23%	3.46%	6.63%	12.52%	1.51%	2.86%
0.10%	29.65%	23.30%	10.69%	5.94%	11.16%	21.08%	2.71%	5.12%
0.25%	49.47%	39.01%	21.30%	11.83%	21.15%	39.96%	5.76%	10.88%
0.40%	62.72%	49.49%	29.94%	16.64%	28.42%	53.69%	8.41%	15.88%
0.50%	69.61%	54.91%	35.08%	19.49%	32.36%	61.13%	10.04%	18.97%
0.75%	82.78%	65.14%	46.46%	25.81%	40.10%	75.74%	13.80%	26.06%
1.00%	92.32%	72.40%	56.40%	31.33%	45.77%	86.46%	17.22%	32.53%
1.30%	100.95%	78.77%	67.00%	37.22%	50.80%	95.95%	21.02%	39.70%
1.50%	105.59%	82.11%	73.45%	40.80%	53.37%	100.81%	23.40%	44.19%
2.00%	114.86%	88.55%	87.94%	48.85%	57.99%	109.53%	28.92%	54.63%
2.50%	122.16%	93.43%	100.64%	55.91%	60.90%	115.03%	33.98%	64.18%
3.00%	128.44%	97.58%	111.99%	62.22%	62.79%	118.61%	38.66%	73.03%
4.00%	139.58%	105.04%	131.63%	73.13%	65.01%	122.80%	47.16%	89.08%
5.00%	149.86%	112.27%	148.22%	82.35%	66.42%	125.45%	54.75%	103.41%
6.00%	159.61%	119.48%	162.52%	90.29%	67.73%	127.94%	61.61%	116.37%
10.00%	193.09%	146.51%	204.41%	113.56%	75.54%	142.69%	83.89%	158.47%
15.00%	221.54%	171.91%	235.72%	130.96%	88.60%	167.36%	103.89%	196.23%
20.00%	238.23%	188.42%	253.12%	140.62%	100.28%	189.41%	117.99%	222.86%

Ek 2 Likidite Karşılama Oranı Bildirimi Cetveli




	YÜKSEK KALİTELİ LİKİT VARLIKLAR	Dikkate Alınma Oranları
A.	Birinci Kalite Likit Varlıklar	
I.	Nakit Değerler ve Merkez Bankaları	
I.1	Kasa	100%
I.2	Efektif Deposu	100%
I.3	TCMB	
I.3.1	Vadesiz Serbest Hesap	100%
I.3.2	Vadeli Serbest Hesap	100%
I.3.3	Zorunlu Karşılıklar	100%
I.4	Yurtdışı Şubelerin Bulunduğu Merkez Bankaları	...%
II.	Kredi Kalitesi Kademesi %0 Risk Ağırlığına Tekabül Edenler Tarafından İhraç Edilen Borçlanma Araçları	
2.1	Ölke Merkezi Yönetimleri, Merkez Bankaları ya da Bunların Garantisiyle İhraç Edilen Borçlanma Araçları	100%
2.2	Kamu Kuruluşları ya da Bunların Garantisiyle İhraç Edilen Borçlanma Araçları	100%
2.3	Uluslararası Ödemeler Bankası, Uluslararası Para Fonu, Avrupa Birliği, Avrupa Merkez Bankası ya da Çok Taraflı Kalkınma Bankaları ya da Bunların Garantisiyle İhraç Edilen Borçlanma Araçları	100%
III.	Kredi Kalitesi Kademesi %0 Risk Ağırlığına Tekabül Etmeyenler Tarafından İhraç Edilen Borçlanma Araçları	
3.1	T.C. Hazine Müsteşarlığı veya TCMB Tarafından Türk Lirası Cinsinden İhraç Edilen Borçlanma Araçları	100%
3.2	T.C. Hazine Müsteşarlığı veya TCMB Tarafından Yabancı Para Cinsinden İhraç Edilen Borçlanma Araçları	100%
3.3	Ölke Merkezi Yönetimleri, Merkez Bankaları Tarafından Ulusal Para Birimleri Cinsinden İhraç Edilen Borçlanma Araçları	
3.3.1	Yurtdışı Şubelerin Bulunduğu Ölke Merkezi Yönetimleri, Merkez Bankaları Tarafından İhraç Edilenler	100%
3.4	Ölke Merkezi Yönetimleri, Merkez Bankaları Tarafından Ulusal Para Birimi Dışındaki Bir Para Birimi Cinsinden İhraç Edilen İhraç Edilen Borçlanma Araçları	
3.4.1	Yurtdışı Şubelerin Bulunduğu Ölke Merkezi Yönetimleri, Merkez Bankaları Tarafından İhraç Edilenler	100%



I.1.1	İstikrarlı Mevduat/Katılım Fonu	5%
I.1.2	Düşük İstikrarlı Mevduat/Katılım Fonu	10%
I.1.3	Diğer Mevduat/Katılım Fonu	... %
I.1.4	Bankaca İhraç Edilen Teminatsız Borçlanma Araçları	10%
I.1.5	Teminatsız Diğer Borçlar	10%
I.2	Perakende Müşterilere Teminatsız Borçlar	
I.2.1	İstikrarlı Mevduat/Katılım Fonu	5%
I.2.2	Düşük İstikrarlı Mevduat/Katılım Fonu	10%
I.2.3	Diğer Mevduat/Katılım Fonu	... %
I.2.4	Bankaca İhraç Edilen Teminatsız Borçlanma Araçları	10%
I.2.5	Teminatsız Diğer Borçlar	10%
I.3.	Diğer Kişilere Teminatsız Borçlar	
I.3.1	Kredi Kuruluşu veya Finansal Kuruluş Dışındaki Kuruluşlara Teminatsız Borçlar	
I.3.1.1	İstikrarlı Operasyonel Mevduat/Katılım Fonu	5%
I.3.1.2	Düşük İstikrarlı Operasyonel Mevduat/Katılım Fonu	25%
I.3.1.3	İstikrarlı Operasyonel Olmayan Mevduat/Katılım Fonu	20%
I.3.1.4	Düşük İstikrarlı Operasyonel Olmayan Mevduat/Katılım Fonu	40%
I.3.1.5	Teminatsız Diğer Borçlar	40%
I.3.2	Merkezi Yönetimler, Merkez Bankaları, Çok Taraflı Kalkınma Bankaları ve Kamu Kurumlarına Teminatsız Borçlar	
I.3.2.1	İstikrarlı Operasyonel Mevduat/Katılım Fonu	5%
I.3.2.2	Düşük İstikrarlı Operasyonel Mevduat/Katılım Fonu	25%
I.3.2.3	İstikrarlı Operasyonel Olmayan Mevduat/Katılım Fonu	20%
I.3.2.4	Düşük İstikrarlı Operasyonel Olmayan Mevduat/Katılım Fonu	40%
I.3.2.5	Teminatsız Diğer Borçlar	40%
I.3.3	Bankalara Teminatsız Borçlar	
I.3.3.1	Operasyonel Mevduat/Katılım Fonu	25%
I.3.3.2	Operasyonel Olmayan Mevduat/Katılım Fonu	100%
I.3.3.3	Teminatsız Diğer Borçlar	100%
I.3.4	Diğer Kuruluşlara Teminatsız Borçlar	
I.3.4.1	Operasyonel Mevduat/Katılım Fonu	25%
I.3.4.2	Operasyonel Olmayan Mevduat/Katılım Fonu	100%
I.3.4.3	Teminatsız Diğer Borçlar	100%




3.1.1	Varlığa Dayalı Menkul Kıymetler	100%
3.1.2	İpotek Teminatlı Menkul Kıymetler	100%
3.1.3	Diğer Yapılandırılmış Finansal Araçlardan Borçlar	100%
3.2	Özel Amaçlı Kuruluşlar gibi Kuruluşlar Aracılığı ile İhraç Edilen Yapılandırılmış Finansal Araçlardan Borçlar	100%
IV.	Bilanço Dışı Borçlar	
4.1	Türev Yükümlülükler	100%
4.2	Bankanın Kredi Derecesinin Düşmesine Bağlı Yükümlülükler	100%
4.3	Verilen Teminatların Gerçeğe Uygun Değerlerinde Değişiklik Olması İhtimaline Bağlı Yükümlülükler	
4.3.1	Teminatın Birinci Kalite Likit Varlık Niteliğinde Olması	0%
4.3.2	Teminatın Birinci Kalite Likit Varlık Niteliğinde Olmaması	20%
4.4	Alınan Teminatların Karşı Tarafça Her An Geri İstenebilme İhtimaline Bağlı Yükümlülükler	100%
4.5	Teminatların Karşı Tarafa Verilme Tarihinin Gelmesinden Kaynaklanan Yükümlülükler	100%
4.6	Alınan Teminatlardan Yüksek Kaliteli Likit Varlık Olanların Bu Türden Olmayan Teminatlarla Değiştirilme İhtimaline Bağlı Yükümlülükler	100%
4.7	Türev İşlemler ve Diğer Yükümlülüklerin Gerçeğe Uygun Değerlerinde Değişiklik Olması İhtimaline Bağlı Yükümlülükler	100%
4.8	Cayılmaz veya Şarta Bağlı Olarak Cayılabilir Diğer Bilanço Dışı Borçlar	
4.8.1	Gerçek Kişilere ve Perakende Müşterilere Yükümlülükler	5%
4.8.2	Mali Olmayan Kuruluşlar, Merkezi Yönetimler, Merkez Bankaları, Kamu Kuruluşları ve Çok Taraflı Kalkınma Bankalarının Finansal Piyasalara Olan Borçları İçin Verilen Ödeme Taahhütleri	30%
4.8.3	Mali Olmayan Kuruluşlar, Merkezi Yönetimler, Merkez Bankaları, Kamu Kuruluşları ve Çok Taraflı Kalkınma Bankalarına Diğer Yükümlülükler	10%
4.8.4	Bankalara Yükümlülükler	40%
4.8.5	Banka Dışındaki Finansal Kuruluşlara Yükümlülükler	
4.8.5.1	Yatırım Ortaklıklarına, Yatırım Kuruluşları ile Konut ve Varlık Finansmanı ile İpotek Finansmanı Kuruluşları gibi Özel Amaçlı Kuruluşlara Yükümlülükler	100%
4.8.5.2	Banka Dışındaki Diğer Finansal Kuruluşların Finansal Piyasalara Olan Borçlarına Verilen Ödeme Taahhütleri	100%
4.8.5.3	Banka Dışındaki Diğer Finansal Kuruluşlara Diğer Yükümlülükler	40%
4.8.6	Müşterinin Açığa Satış İşleminde Kaynaklanan Pozisyonunun Başka Bir Müşterinin Yüksek Kaliteli Likit Varlık Niteliğinde Olmayan Teminatı ile Karşılanmasından Doğan Yükümlülükler	50%
4.8.7	Bankanın Açığa Satış İşleminde Kaynaklanan Pozisyonunun Menkul Kıymet Ödünç Piyasası Dışından Sağlanan Menkul Kıymetle Karşılanmasından Doğan Yükümlülükler	100%
4.8.8	Diğer Cayılmaz veya Şarta Bağlı Olarak Cayılabilir Diğer Bilanço Dışı Borçlar (Dış Ticaretin Finansmanı ile Mal ve Hizmet Alımına İlişkin Taahhütler)	5%
4.8.9	Diğer Cayılmaz veya Şarta Bağlı Olarak Cayılabilir Diğer Bilanço Dışı Borçlar	100%
4.9	Herhangi Bir Şarta Bağlı Olmaksızın Cayılabilir Bilanço Dışı Diğer Yükümlülükler	5%

4.1.6	2A Kalite Likit Varlık Verilip Karşılığında Birinci Kalite Likit Varlık Alınması	15%
4.1.7	2A Kalite Likit Varlık Verilip Karşılığında 2A Kalite Likit Varlık Alınması	0%
4.1.8	2A Kalite Likit Varlık Verilip Karşılığında Konut Finansmanından Kaynaklanan İpoteğe Dayalı Menkul Kıymet Alınması	
4.1.9	2A Kalite Likit Varlık Verilip Karşılığında Diğer 2B Kalite Likit Varlık Alınması	
4.1.10	2A Kalite Likit Varlık Verilip Karşılığında Diğer Varlıkların Alınması	
4.1.11	Konut Finansmanından Kaynaklanan İpoteğe Dayalı Menkul Kıymet Verilip Karşılığında Birinci Kalite Likit Varlık Alınması	25%
4.1.12	Konut Finansmanından Kaynaklanan İpoteğe Dayalı Menkul Kıymet Verilip Karşılığında 2A Kalite Likit Varlık Alınması	10%
4.1.13	Konut Finansmanından Kaynaklanan İpoteğe Dayalı Menkul Kıymet Verilip Karşılığında Konut Finansmanından Kaynaklanan İpoteğe Dayalı Menkul Kıymet Alınması	0%
4.1.14	Konut Finansmanından Kaynaklanan İpoteğe Dayalı Menkul Kıymet Verilip Karşılığında Diğer 2B Kalite Likit Varlık Alınması	
4.1.15	Konut Finansmanından Kaynaklanan İpoteğe Dayalı Menkul Kıymet Verilip Karşılığında Diğer Varlıkların Alınması	
4.1.16	Diğer 2B Kalite Likit Varlık Verilip Karşılığında Birinci Kalite Likit Varlık Alınması	50%
4.1.17	Diğer 2B Kalite Likit Varlık Verilip Karşılığında 2A Kalite Likit Varlık Alınması	35%
4.1.18	Diğer 2B Kalite Likit Varlık Verilip Karşılığında Konut Finansmanından Kaynaklanan İpoteğe Dayalı Menkul Kıymet Alınması	25%
4.1.19	Diğer 2B Kalite Likit Varlık Verilip Karşılığında Diğer 2B Kalite Likit Varlık Alınması	0%
4.1.20	Diğer 2B Kalite Likit Varlık Verilip Karşılığında Diğer Varlıkların Alınması	
4.1.21	Diğer Varlıkların Verilip Karşılığında Birinci Kalite Likit Varlık Alınması	100%
4.1.22	Diğer Varlıkların Verilip Karşılığında 2A Kalite Likit Varlık Alınması	85%
4.1.23	Diğer Varlıkların Verilip Karşılığında Konut Finansmanından Kaynaklanan İpoteğe Dayalı Menkul Kıymet Alınması	75%
4.1.24	Diğer Varlıkların Verilip Karşılığında Diğer 2B Kalite Likit Varlık Alınması	50%
4.1.25	Diğer Varlıkların Verilip Karşılığında Diğer Varlıkların Alınması	0%
4.2	Teminatı Açığa Satış İşleminde Kaynaklanan Pozisyonu Kapatmada Kullanılanlar	
4.2.1	Birinci Kalite Likit Varlık Verilip Karşılığında Birinci Kalite Likit Varlık Alınması	0%
4.2.2	Birinci Kalite Likit Varlık Verilip Karşılığında 2A Kalite Likit Varlık Alınması	
4.2.3	Birinci Kalite Likit Varlık Verilip Karşılığında Konut Finansmanından Kaynaklanan İpoteğe Dayalı Menkul Kıymet Alınması	
4.2.4	Birinci Kalite Likit Varlık Verilip Karşılığında Diğer 2B Kalite Likit Varlık Alınması	
4.2.5	Birinci Kalite Likit Varlık Verilip Karşılığında Diğer Varlıkların Alınması	
4.2.6	2A Kalite Likit Varlık Verilip Karşılığında Birinci Kalite Likit Varlık Alınması	15%
4.2.7	2A Kalite Likit Varlık Verilip Karşılığında 2A Kalite Likit Varlık Alınması	0%


Ek 3 Değişkenler Arası İlişki Grafikleri










Ek 4 SAS Model Geliştirme Akış Şemaları









Ek 5 Rassal Orman Python Geliştirme Kodu

```
1 # -*- coding: utf-8 -*-
2 """
3 Created on Mon Dec 6 12:01:20 2021
4
5 @author: arda
6 """
7
8
9 import pandas as pd
10 from sklearn.ensemble import RandomForestClassifier
11
12
13
14 veri_seti = pd.read_csv('bankloans.csv')
15
16
17 temerrut = veri_seti.iloc[:, -1:]
18 temerrut = temerrut.fillna(0)
19 baginsiz_degisenler = veri_seti.iloc[:, :-1]
20
21
22 rf = RandomForestClassifier(n_estimators = 300, random_state=0)
23 rf.fit(baginsiz_degisenler, temerrut)
24
25 tahminler = rf.predict(baginsiz_degisenler)
26 tahminler_olasilik = rf.predict_proba(baginsiz_degisenler)[:, 1:]
27 df = pd.DataFrame(tahminler_olasilik, columns=['default_prob'])
28
29 result = pd.concat([baginsiz_degisenler, df], ignore_index=True, sort=False)
30
31
32
```

Name	Type	Size	Value
baginsiz_degisenler	DataFrame	(850, 8)	Column names: age, ed, employ, address, income, debtinc, creddebt, oth ...
df	DataFrame	(850, 1)	Column names: default_prob
result	DataFrame	(1700, 9)	Column names: age, ed, employ, address, income, debtinc, creddebt, oth ...
tahminler	Float64	(850,)	[1. 0. 0. ... 0. 0. 0.]
tahminler_olasilik	Float64	(850, 1)	[[0.70333333] [0.10333333]]
temerrut	DataFrame	(850, 1)	Column names: default
veri_seti	DataFrame	(850, 9)	Column names: age, ed, employ, address, income, debtinc, creddebt, oth ...

Variable explorer | File explorer | Help

Python console

Console 1/1

Python 3.7.3 (default, Mar 27 2019, 17:13:21) [MSC v.1915 64 bit (AMD64)]
Type "copyright", "credits" or "license()" for more information.

IPython 7.4.0 -- An enhanced Interactive Python.

In [1]:

In [1]: runfile('C:/Users/FQ28Q/NL_Mortgages_IFRS9/random_forest.py', wdir='C:/Users/FQ28Q/NL_Mortgages_IFRS9')
C:/Users/FQ28Q/NL_Mortgages_IFRS9/random_forest.py:23: DataConversionWarning: A column-vector y was passed when a 1d array was expected. Please change the shape of y to (n_samples,), for example using ravel().
rf.fit(baginsiz_degisenler, temerrut)

In [2]: runfile('C:/Users/FQ28Q/NL_Mortgages_IFRS9/random_forest.py', wdir='C:/Users/FQ28Q/NL_Mortgages_IFRS9')
Reloaded modules: win32com, win32api, pywintypes, win32sysloader, win32con, shell
C:/Users/FQ28Q/NL_Mortgages_IFRS9/random_forest.py:23: DataConversionWarning: A column-vector y was passed when a 1d array was expected. Please change the shape of y to (n_samples,), for example using ravel().
rf.fit(baginsiz_degisenler, temerrut)

In [3]:

Ek 6 SAS Model Geliştirme Kodlar - 1



```
1 | libname inp '/opt/sas/data/vaa_mvsv/sasdata/squad_nl/Users/Arda';  
2 | libname out '/opt/sas/data/vaa_mvsv/sasdata/squad_nl/Users/Arda/Tez';  
3 |
```



```

25
26 □ proc sgplot data=inp.bankloans ;
27   histogram age;
28   xaxis label='Yas';
29   yaxis label='Yuzde';
30   title 'Yas Bilgileri';
31   run;
32
33 □ proc sgplot data=inp.bankloans ;
34   histogram ed;
35   xaxis label='ed';
36   yaxis label='Yuzde';
37   title 'ed Bilgileri';
38   run;
39
40 □ proc sgplot data=inp.bankloans ;
41   histogram employ;
42   xaxis label='Calisma Duzeyi';
43   yaxis label='Yuzde';
44   title 'Calisma Duzeyi Bilgileri';
45   run;
46
47
48 □ proc sgplot data=inp.bankloans ;
49   histogram address;
50   xaxis label='Adres';
51   yaxis label='Yuzde';
52   title 'Adres Bilgileri';
53   run;
54
55 □ proc sgplot data=inp.bankloans ;
56   histogram income;
57   xaxis label='Gelir';
58   yaxis label='Yuzde';
59   title 'Gelir Bilgileri';
60   run;
61
62 □ proc sgplot data=inp.bankloans ;
63   histogram debtinc;
64   xaxis label='Gelir Borc';
65   yaxis label='Yuzde';
66   title 'Gelir Borc Duzeyi Bilgileri';
67   run;
68
69


```

Ek 7 Model Girdileri Frekans Grafikleri







Calisma Duzeyi Bilgileri




Gelir Borc Duzeyi Bilgileri




Kredi Borc Duzeyi Bilgileri





Ek 8 Jeffrey Testi - SAS



Code	Results	Log
1	% eg_conditional_drops(WORK.QUERY_FOR_XGBOOST_FINAL);	
2		
3	PROC SQL;	
4	CREATE TABLE WORK.QUERY_FOR_XGBOOST_FINAL AS	
5	SELECT t1.Pool,	
6	/* AVG_of_LRA */	
7	(AVG(t1.LRA)) AS AVG_of_LRA,	
8	/* COUNT_of_musteri_no */	
9	(COUNT(t1.musteri_no)) AS COUNT_of_musteri_no,	
10	/* SUM_of_observed_default_flag */	
11	(SUM(t1.observed_default_flag)) AS SUM_of_observed_default_flag	
12	FROM TMP00002.xgboost_final t1	
13	GROUP BY t1.Pool;	
14	QUIT;	