

Rassal Orman Algoritmasına Dayalı Olarak Türkiye’de Finansal Krizlerin Tahminlenmesi

Forecasting Financial Crises in Türkiye Based on Random Forest Algorithm

Merve MERT SARITAŞ^a

Mert URAL^b

Öz

Bu çalışma, finansal krizlerin önceden tahmin edilebilirliğinin ekonomik ve sosyal maliyetleri azaltmadaki kritik rolünden hareketle, Türkiye’de finansal krizleri öncü göstergeler aracılığıyla tahmin etmeyi amaçlayan bir erken uyarı sistemi geliştirmeyi hedeflemektedir. 2004-2024 dönemi için, uluslararası rezervler, döviz kuru ve faiz oranları kullanılarak oluşturulan Finansal Baskı Endeksi (FBE) ile 8 farklı finansal kriz dönemi tespit edilmiş ve Türkiye ekonomisine ait 18 temel makroekonomik ve finansal gösterge kullanılarak rassal orman algoritmasının tahmin performansı değerlendirilmiştir. Elde edilen sonuçlar, rassal orman algoritmasının kriz tahmininde yüksek bir başarı sergilediğini ortaya koymakta, finansal krizlerin temel ekonomik belirleyicilerinin belirlenmesine olanak sağlayarak politika yapıcılar için kapsamlı bir karar alma sürecini desteklemektedir. Bu çalışma, finansal kriz tahmininde makine öğrenmesi yöntemlerinin potansiyelini vurgularken modelin yorumlanabilirliğinin de altını çizerek finansal istikrarın sağlanmasına yönelik politika önerileri sunmaktadır.

Anahtar Kelimeler: Tahminleme, finansal krizler, rassal orman, finansal baskı endeksi.

JEL Sınıflandırması: C53, G01, G17.

Abstract

The aim of this study is to develop an early warning system to predict financial crises in Türkiye through leading indicators. This is based on the critical role of forecasting financial crises in reducing economic and social costs. The study utilises the Exchange Market Pressure Index (EMPI), a metric constructed using international reserves, exchange rates, and interest rates, to identify eight distinct financial crisis periods during the period spanning from 2004 to 2024. The random forest algorithm’s forecasting performance is evaluated using 18 key macroeconomic and financial indicators of the Turkish economy. The results demonstrate that the random forest algorithm demonstrates a high degree of success in crisis forecasting and supports a comprehensive decision-making process for policymakers by enabling the identification of the main economic determinants of financial crises. While emphasising the potential of machine learning methods in financial crisis forecasting, the study also highlights the interpretability of the model and provides policy recommendations for financial stability.

Keywords: Forecasting, financial crisis, random forest, exchange market pressure index.

JEL Classification: C53, G01, G17.

^a Arş. Gör. Dr., Çanakkale Onsekiz Mart Üniversitesi, Siyasal Bilgiler Fakültesi, e-mail: merve.mertsaritas@comu.edu.tr, ORCID ID: 0009-0009-4549-1679

^b Prof. Dr., Dokuz Eylül Üniversitesi, İktisadi İdari Bilimler Fakültesi, e-mail: mert.ural@deu.edu.tr, ORCID ID: 0000-0003-3252-846X

1. Giriş

Finansal krizler, literatürde farklı kavramsal çerçevelerden ele alınmaktadır. Mishkin (1996), krizleri finansal piyasaların etkin kaynak tahsisini sektöre uğratarak ekonomik büyüme üzerinde olumsuz yaratan ciddi bir bozulma olarak tanımlarken, Goldstein ve Turner (1998) ani ve keskin finansal gösterge kötüleşmeleri olarak ifade etmektedir. Alternatif bir perspektif sunan Kindleberger (2000) ise finansal krizleri, ekonomik konjonktürün zirve noktasındaki dönüşüm süreçlerinin doğal bir sonucu olarak değerlendirmektedir.

Tanımı ne olursa olsun, finansal krizlerin yol açtığı derin ekonomik ve sosyal maliyetler, istikrarsızlık ve şoklar göz önüne alındığında, bu olguların önceden tahmin edilmesi makroekonomik istikrarın korunması ve proaktif politika müdahalelerinin tasarlanması açısından hayati bir gereklilik olarak öne çıkmaktadır. Zira finans sektöründeki yaygın olumsuzlukların reel ekonomi üzerindeki yansımaları hem politika yapıcılar hem de akademisyenler için önemli bir araştırma gündemi oluşturmaktadır.

Finansal krizlerin tespiti ve tahmini alanındaki öncü çalışmalar, Kaminsky vd. (1998) tarafından 103 potansiyel gösterge arasından finansal krizler üzerinde önemli olan 16 etkili değişkenin belirlenmesiyle ivme kazanmıştır. Zaman içinde, özellikle 2008-2009 küresel finans krizi sonrası artan finansal istikrar vurgusuyla, kriz sinyallerinin tespiti için çeşitli metodolojiler geliştirilmiştir. Bu metodolojiler arasında, piyasa baskısını ve finansal sistemdeki stresi ölçmeye yönelik Finansal Baskı Endeksi (FBE) ve Finansal Stres Endeksi (FSE) gibi kompozit göstergeler literatürde yaygın kabul görmüş ve birçok araştırmanın (örneğin, Pentecost vd., 2001; Pontines ve Siregar, 2008; Aizenman ve Binici, 2016; Soe ve Kakinaka, 2018; Özcebe vd., 2024) temelini oluşturmuştur. Bu endekslerin makroekonomik değişkenler üzerindeki etkileri (Polat ve Özkan, 2019; Tuzcuoglu, 2024; Giannellis ve Tzanaki, 2025) ve döviz kurları gibi kritik fiyatlarla etkileşimleri (Apostolakis vd., 2019; Ishrakieh vd., 2019) de ayrıca incelenmiştir.


Ancak, finansal sistemlerin ve kriz dinamiklerinin güncel faktörlere bağlı artan karmaşıklığı, geleneksel ekonometrik yöntemlerin öngörü kapasitesindeki sınırlılıkları ortaya koymuştur. Finansal kriz öngörüsü için doğrusal olmayan yapıları çözümleyebilen ve veriye dayalı öğrenme sağlayan makine öğrenmesi tekniklerinin gelişimi bu alana yeni bir boyut kazandırmıştır (Yıldırım vd., 2011). Bu teknikler, özellikle politika yapıcılar için kritik önem taşıyan Erken Uyarı Sistemleri (EWS) geliştirilmesinde kullanılarak sistematik bankacılık krizlerinden borsa krizlerine, finansal balonlardan oynaklık yayılımına kadar geniş bir yelpazede tahminleme gücünü artırma potansiyeli sunmaktadır.

Türkiye ekonomisi de geçmişte çeşitli finansal krizler deneyimlemiş olup bu krizlerin ekonomik ve sosyal etkileri dikkate alındığında, ülke özelinde etkin kriz tahmin modellerinin geliştirilmesi büyük önem arz etmektedir. Nitekim Türkiye'de FBE kullanarak kriz dönemi tahmini yapan çalışmalar bulunmaktadır. Stolbov ve Shchepeleva (2016), Türkiye'nin de dahil olduğu 14 gelişmekte olan ülke için 2008-2015 verilerini kullanarak FBE aracılığıyla finansal stresi analiz etmiş ve finansal stresin dokuz ülkede ekonomik faaliyetleri olumsuz etkilediğini saptamıştır. Ayrıca, ülkeler arası finansal stres yayılımını incelemek üzere bir Bayesian VAR modeli kullanılmıştır. Emin (2017) ise 1993-2015 dönemi Türkiye verileriyle FBE kullanarak beş finansal kriz dönemi belirlemiş ve bu dönemlerin makroekonomik ve finansal göstergelerini analiz ederek, 28 değişkenden yedisinin tüm kriz dönemlerinde anlamlı öncü göstergeler olduğunu tespit etmiştir. Bu bulgular, Türkiye'deki finansal krizlerin erken sinyallerini anlamak için önemli bir zemin oluşturmaktadır. Bu çalışmalar Türkiye'deki kriz dinamiklerini anlamak için önemli bir temel sunsa da kullanılan yöntemler ve veri setlerinin güncelliği açısından geliştirilmeye açıktır.

Bu çalışma, söz konusu literatürdeki gelişmelerden ve boşluklardan hareketle, 2004 Ocak – 2024 Aralık dönemini kapsayan güncel bir veri seti ve geniş bir öncü gösterge havuzu kullanarak Türkiye için bir Finansal Baskı Endeksi (FBE) oluşturmayı ve bu endeksi rassal orman makine öğrenmesi algoritması ile modelleyerek finansal krizleri tahminlemeyi amaçlamaktadır. Şekil 1'de bu çalışma kapsamında FBE ile belirlenen kriz dönemleri görselleştirilmektedir. Çalışmanın temel özgünlüğü, Türkiye özelinde FBE tabanlı kriz analizini güncel ve genişletilmiş bir zaman dilimine taşıması, kapsamlı bir değişken setiyle rassal orman gibi literatürde Türkiye için finansal kriz tahmininde görece az kullanılmış güçlü bir

makine öğrenmesi modelini uygulaması ve bu süreçte dengesiz veri problemine yönelik uygun teknikleri içermesidir.

Şekil 1. Türkiye’de Kriz Dönemleri



Çalışmanın ikinci bölümünde detaylı bir literatür incelemesi yer alırken üçüncü bölümde veri seti ve tahmin edici değişkenlere ilişkin kapsamlı bilgi sunulmaktadır. Dördüncü bölümde metodoloji aktarılmakta ve FBE ile uygulanan makine öğrenmesi modeli özetlenmektedir. Çalışmanın beşinci ve son bölümünde ise temel bulgular özetlenerek ekonomik yorumları sunulmakta ve rassal orman algoritması aracılığıyla Türkiye'deki kriz dönemi tahmin edicilerinin göreceli önem düzeyleri belirlenmektedir.

2. Literatür

Finansal krizlerin öngörülmesi, makroekonomik istikrarın sürdürülebilirliği açısından kritik bir araştırma alanı teşkil etmekte olup, bu alandaki çalışmalar genellikle krizlere işaret eden öncü göstergelerin tanımlanması üzerine yoğunlaşmaktadır. Literatürün erken dönemlerinde hem uluslararası düzeyde hem de Türkiye bağlamında gerçekleştirilen ampirik analizlerde, Finansal Baskı Endeksi (FBE) gibi geleneksel sinyal yaklaşımları benimsenerek döviz kuru hareketleri, rezerv yeterliliği ve kredi hacmi gibi makro-finansal değişkenler aracılığıyla kriz olasılıkları değerlendirilmiştir. Ancak, küresel finansal entegrasyonun derinleşmesi ve piyasa dinamiklerinin artan karmaşıklığı, daha gelişmiş tahmin modellerine yönelik ihtiyacı belirginleştirmiş ve araştırma odağını yapay zekâ ile makine öğrenmesi temelli metodolojilere kaydırmıştır.

Finansal krizlerin öncü göstergeleri üzerine yapılan çalışmalarda, Eichengreen vd. (1996) 20 gelişmiş ülkede 1959-1993 dönemine ait FBE kullanarak uluslararası rezervler ve yurtiçi kredi hacminde azalma, faiz oranlarında yükseliş, ithalatta artış, para arzı ve kredi hacmi büyüme oranlarında artış, cari işlemler ve bütçe açığında genişleme ile ihracat, istihdam ve büyüme oranlarında düşüşünü kriz göstergesi olarak belirlemiştir. Frankel ve Rose (1996), 1971-1992 yıllarına ait 105 gelişmekte olan ülkede ulusal paranın nominal olarak %25'ten fazla değer kaybetmesini kriz sayarak, azalan doğrudan yabancı yatırım, rezervlerdeki düşüş, artan kredi hacmi, gelişmiş ülke faizleri ve aşırı değerli kuru anlamalı bulmuştur. Kaminsky vd. (1998), 1970-1995 döneminde 15 gelişmekte olan ülke için FBE ile reel kur artışı, ithalat yükselişi, rezervler ve borsa endeksindeki düşüşü, para arzı/uluslararası rezerv oranında artış ve çıktı azalmasını öncü sinyal olarak tespit etmiştir. Benzer şekilde Edison (2003), 1970-1995 yılları arası 20 ülkede FBE ile yükselen döviz kurları, artan M2/rezerv oranı, azalan rezervler ve düşen hisse senedi fiyatlarını anlamalı öncü göstergeler olduğunu göstermiştir. Türkiye özelinde Kaya ve Yılmaz

(2007), 2003-2005 dönemi için bütçe dengesi bozulması, M2/kısa vadeli borç oranı, dış ticaret hadleri/GSMH oranı ve reel kur değerlenmesini; Çeşmeci ve Önder (2008) ise 1992-2004 dönemi için para piyasası baskı endeksi, reel sektör güven endeksi, kamu borcu ve bütçe dengesi/GSYİH oranını öncü göstergeler olarak saptamıştır. Daha geniş bir tarihsel perspektifle Reinhart ve Rogoff (2011), 1800-2006 dönemi için 70 ülkede ulusal paranın Amerikan doları ya da bir denge döviz karşısında yıllık %15'lik değer kaybını kriz kabul ederek artan enflasyon ile kamu/özel sektör borçlarının kriz olasılığını artırdığını belirtmiştir. Avcı ve Altay (2013), Türkiye dahil dört ülkede (1990-2010) FBE ile reel faiz oranı, reel kurun trendden sapması, para piyasası baskı endeksi ve yurtiçi krediler/sanayi üretimi oranındaki artışı anlamlı göstergeler olarak ortaya koymuştur. Türkiye'deki ekonomik krizleri ve öncü göstergelerini ele alan çalışmalara bakıldığında, Karabulut vd. (2010), 1994 ve 2001 Türkiye krizlerini sıralı lojistik regresyon ile tahminlemeye çalışmış, nominal döviz kuru değişimlerini temel alarak kriz dönemlerini tanımlamışlardır. Analizler sonucunda, kısa vadeli borçlar/GSYH, reel döviz kuru, mevduat faiz oranı, uluslararası döviz rezervleri/ithalat ve krediler/mevduat değişkenlerinin para krizlerini tahmin etmede etkili olduğu bulunmuştur. Avcı ve Altay (2014), 1990-2010 döneminde Türkiye, Arjantin, Meksika, Malezya ve Tayland'daki finansal krizlerin öngörülebilirliğini regresyon ağaçları modeliyle incelemiş ve FBE'yi açıklayan 15 gösterge kullanmıştır. Para piyasası baskı endeksi, M2'nin rezervlere oranı ve yurtiçi kredilerin endüstriyel üretime oranının en başarılı göstergeler olduğu belirlenmiş ve regresyon ağaçları modeliyle çeşitli ülke krizleri başarıyla öngörülmüştür. Söyler ve Kızılkaya (2018), Türkiye için para krizi tahmininde YSA yönteminin oldukça başarılı sonuçlar verdiğini göstermiştir. En iyi performansa sahip YSA modelinin ağırlıklı değişken değerleri incelendiğinde, Türkiye'deki para krizlerini en çok etkileyen üç değişkenin sırasıyla reel efektif döviz kuru, mevduat faiz oranları ve ihracat birim değeri olduğu sonucuna ulaşılmıştır.

Dünya ekonomisindeki entegrasyonun artması, finans piyasalarındaki sınırların ortadan kalkmasına ve finansal krizlerin yayılım hızının ve etkilerinin artmasına yol açmıştır. Finansal krizlerin olumsuz etkilerini azaltmak ve ekonomik istikrarı destekleyici politikaları hayata geçirebilmek amacıyla makine öğrenmesi yöntemlerinden yararlanan çalışmalar yapılmıştır. Bu kapsamda Aydın ve Çavdar (2015), Türkiye ekonomisi (1990-2014) için çok katmanlı ileri beslemeli sinir ağları kullanarak geliştirdikleri erken uyarı sisteminin finansal riskleri başarılı bir şekilde öngördüğünü ve 2014-2016 arası tehditleri işaret ettiğini bulmuştur. Akçalı (2015), MIST ülkelerinde FBE, Box-Jenkins ve Yapay Sinir Ağları (YSA) modellerini kullanarak yaptığı analizde, Aralık 2014-Mart 2015 dönemi için düşük kriz olasılığı tespit etmiş ve yöntemlerin kısa vadeli tahmin potansiyelini vurgulamıştır. Özcelebi (2020), finansal stres endeksi şoklarının gelişmekte olan ülkelerdeki FBE üzerindeki asimetric ve dengeleyici/dengesizleştirici etkilerini farklı baskı rejimleri altında incelemiştir. Yakın zamanda Kas ve Çırpıcı (2024), Türkiye'de çok katmanlı algılayıcı modeli kullanarak finansal kriz dönemleri ile normal dönemleri %100 doğrulukla ayırt edebildiklerini göstermiştir.

Erken uyarı sistemleri (EWS), belirli bir dönemde tanımlanmış muhtemel krizleri öngörmek için geliştirilen ve potansiyel öncü göstergelerin belirlenmesini içeren düzeneklerdir. Küresel kriz dönemlerinde ülkelerin kırılganlıklarını tespit ederek politika yapımcıların önleyici tedbirlere odaklanmasına yardımcı olan EWS, düzenleyici kurumları ekonomik krizlerden korunmada desteklerken, bu alandaki ampirik araştırmalar nispeten yeni bir alanı teşkil etmektedir. Yapay zekâ ve makine öğrenimi, EWS çalışmalarına yeni bir perspektif sunmuştur. Davis ve Karim (2008), ülke özelindeki krizler için sinyal modelinin, küresel stresin tespiti için ise regresyon modelinin daha uygun olduğunu belirtmiş ve EWS'lerin genellikle karşı taraf riskleri ve likidite ihtiyaçlarından kaynaklanan kriz olasılığını göz ardı ettiğine dikkat çekmiştir. Duttagupta ve Cashin (2011) bankacılık krizlerini analiz etmek için ikili sınıflandırma ağacı modelini kullanmıştır. Alessi ve Detken (2018), 21 Avrupa Birliği ülkesine ait makroekonomik göstergeler ve kredi değişkenlerini kullanarak rassal orman modelini lojistik regresyonla karşılaştırmış ve AUC değeri %0,93 ile bankacılık krizlerini tahmin etmeyi amaçlamışlardır. Holopainen ve Sarlin (2017) ise geleneksel modellerin k-en yakın komşular, sinir ağları ve topluluk öğrenmesi gibi yöntemlerle iyileştirilebileceğini göstermiştir. Beutel vd. (2019) 17 Avrupa Birliği ülkesi ve ABD verilerini kullanarak varlık fiyat oynaklığı, makroekonomik değişkenler, konut

fiyatları ve borsa endeksleri gibi 10 farklı değişkenle lojistik regresyon, k-NN, karar ağaçları, rassal ormanlar, SVM ve sinir ağı modellerini sistemik bankacılık krizlerini tahmin etmek için değerlendirmişler, lojit modelinden daha iyi performans gösterdiğini ortaya koyarak, EWS için makine öğrenimi modellerinin geliştirilmesinin önemini vurgulamıştır. Chatzis vd. (2018), Asya, Amerika, Avrupa ve Global piyasalara ait hisse senedi endeksleri, faiz oranları, döviz kurları ve ek değişkenleri kullanarak çeşitli makine öğrenimi algoritmaları (SVM, rassal orman, CART, naif bayes, lojistik regresyon ve DNN) ile borsa krizlerini tahmin etmeye çalışmışlardır. Tölö (2020), Avustralya, Belçika, Kanada dahil olmak üzere 17 gelişmiş ülkenin makroekonomik verilerini kullanarak tek gizli katmanlı MLP ve LSTM ile GRU sinir ağı modellerini karşılaştırmış ve sistemik bankacılık krizlerini tahmin etmeyi hedeflemişlerdir. Bluwstein vd. (2023), doğrusal olmayan makine öğrenimi modellerinin, örneklem dışı tahminlerde lojit modelinden üstün performans sergilediğini belirtirken, Casabianca vd. (2022), AdaBoost algoritmasının örneklem dışı lojit modelinden daha iyi tahminler ürettiğini göstermiş ve bankacılık krizlerinin belirleyicilerini sıralamak için makine öğrenimini kullanmıştır. Liu vd. (2022), Shapley değerli ayrıştırma ve Shapley regresyonu yöntemleriyle daha etkili tahmin göstergelerini belirlemiş ve makine öğrenimi modellerinin nedenselliğini analiz ederek, gradient boosting, rassal orman ve topluluk modellerinin lojistik modelden daha iyi sonuçlar verdiğini ortaya koymuştur. Yapay zekâ ve makine öğrenimi uygulamalarının yaygınlaşmasıyla birlikte, kriz öngörü faktörlerine, etkileşim değişkenlerine ve kurumlar arası ilişkilere dair verilerin elde edilmesi kolaylaşmakta (Lin vd., 2008; Huang vd., 2019), bu durum araştırma etkinliğini ve EWS'nin başarısını potansiyel olarak artırmaktadır. Truong vd. (2022), çeşitli Asya ülkeleri için makro-finansal dinamik faktör modelleriyle küresel ve ulusal göstergelerden elde ettikleri faktörlerin, lojistik regresyon ile kullanıldığında finansal krizleri tahmin etmede önemli bir güce sahip olduğunu göstermiştir.

Mevcut literatürde, Türkiye'deki finansal krizlerin erken teşhisi genellikle geleneksel ekonometrik yöntemlerle ele alınmakta, makine öğrenmesi yaklaşımlarının kullanımı ise sınırlı kalmaktadır. Kriz tahmini alanında YSA'nın yaygınlığı, diğer denetimli makine öğrenmesi algoritmalarının potansiyel katkılarının göz ardı edilmesine neden olmuştur. Bu çalışma, 2004 Ocak–2024 Aralık dönemini kapsayan verilerle Türkiye için bir Finansal Baskı Endeksi (FBE) oluşturmayı ve bu endeksi rassal orman algoritması ile bütünleştirerek finansal krizlerin öncü göstergelerini tahmin etmeyi amaçlamaktadır. Çalışmada rassal orman algoritması tarafından sınıflandırılan “kriz var” ve “kriz yok” durumları finansal baskı endeksiyle belirlenmiştir. Çalışmanın özgün katkıları arasında SMOTE (sentetik azınlık artırma yöntemi) gibi dengesiz veri kümeleri için uygun veri ön işleme tekniklerinin kullanılması, rassal orman modelinin etkinlik ve güvenilirliğinin model doğrulama süreçleriyle değerlendirilmesi ve Türkiye'de finansal krizlerin oluşumunda rol oynayan etmenlerin kapsamlı bir şekilde incelenmesi bulunmaktadır. Bu sayede, Türkiye'deki finansal krizlerin erken uyarısı için daha güçlü, anlaşılabilir ve uygulanabilir bir modelleme çerçevesi sunulması hedeflenmektedir. Tüm bu çalışmada Python programlama dili kullanılmıştır.

3. Veri Seti

Bu çalışma, ilk aşamada Türkiye için Ocak 2004 – Aralık 2024 dönemine ait aylık verilerle güvenilir bir kriz tanımı temelinde FBE oluşturularak kriz dönemlerini belirlemeyi ardından ise bu krizlerin habercisi olabilecek öncü göstergelerle kriz dönemlerini makine öğrenmesi yöntemlerinden rassal orman yöntemiyle tahmin etmeyi hedeflemektedir. İlk aşama için FBE'yi oluşturan uluslararası rezervlerdeki ve nominal kurlardaki değişimlerin ağırlıklı ortalaması ile yurtiçi faiz oranlarındaki değişim verileri kullanılırken öncü göstergeler kullanılarak finansal kriz dönemi tahmini olan ikinci aşama için literatürdeki temel çalışmalardan yararlanılarak geniş kapsamlı bir veri seti oluşturulmuştur. Öncü göstergeler, makroekonomi ve finans literatüründe anlamlı sonuçlar sunan ve kriz tahmininde başarılı olduğu kabul edilen 23 adet makroekonomik ve finansal değişkenden meydana gelmektedir. Oluşturulan veri setine ve veri kaynaklarına ilişkin detaylı bilgiler, Tablo 1'de özetlenerek sunulmuştur.

Tablo 1. Finansal Kriz Tahminlemesinde Kullanılan Değişkenler ve Açıklamaları

Veriler	Veri Kaynağı	Açıklama
reel_kur	EVDS	TÜFE Bazlı Reel Efektif Döviz Kuru (2003=100)
usd	EVDS	Nominal ABD Doları/TL Kuru
BİST100	EVDS	Borsa İstanbul 100 Endeksi - Değişim(%)
M2/uarezervler	EVDS	Geniş Para Arzı / Uluslararası Rezervler
enflasyon	EVDS	Tüketici Fiyat Endeksi
tüketici_güven	TÜİK	Tüketici Güven Endeksi
dyük/dvar	EVDS	Dış Yükümlülükler / Dış Varlıklar
TCMB_politika_faizi	IFS	TCMB Politika Faiz Oranı
net_portföy	EVDS	Net Portföy Yatırımları
M2	EVDS	Geniş Para Arzı - Değişim(%)
uarezervler	EVDS	Uluslararası Rezervler
mevduat_faiz	EVDS	TL Üzerinden Açılan Mevduat Faiz Oranı
TCMB_rezerv	EVDS	TCMB Rezervleri
tmevduat	EVDS	Toplam Mevduat - Değişim(%)
icborcstok	EVDS	İç Borç Stoğu - Değişim(%)
cari_acık	EVDS	Cari Açık - Değişim(%)
SÜE	TÜİK	Sanayi üretim endeksi (Toplam Sanayi)
dış_tic_haddi	TÜİK	Dış Ticaret Hadleri (2015=100) USD - Değişim(%)
dış_açık	TÜİK	Dış Ticaret Dengesi - Değişim(%)
X/M Karşılama Oranı	TÜİK	İhracatın İthalatı Karşılama Oranı
(X - M) / SÜE	TÜİK	(İhracat - İthalat) / SÜE
Bütçe Dengesi	HMB	Bütçe Dengesi - Değişim(%)
CDS	Investing	Türkiye 5 Yıllık CDS Primi

Bu çalışmada, Türkiye’de krizleri açıklamada etkili olduğu düşünülen reel sektör, finansal sektör ve ödemeler dengesi değişkenleri ile ekonomide borçluluk durumları gibi toplam 23 farklı değişkenin, kriz dönemlerini tahmin etmede erken uyarı sağlayacak nitelikte olup olmadıkları ve önem dereceleri analiz edilmektedir.

Tablodaki verilerden "usd", "mevduat_faiz" ve "uarezervler" değişkenleri FBE hesaplamasında kullanılırken, diğer değişkenler Türkiye'deki kriz dönemlerinin tahmini için makroekonomik ve finansal öncü göstergeler olarak değerlendirilmiştir.

4. Yöntem

4.1. Finansal Baskı Endeksi

Eichengreen vd. (1996) tarafından geliştirilen FBE, nominal döviz kuru (K), faiz oranı (F) ve rezervlerde (R) meydana gelen ağırlıklı ortalama değişimler temel alınarak oluşturulmaktadır. Endekse negatif işaretle dahil edilen rezerv değişimi, belirlenecek ağırlıkların kesin olmaması nedeniyle eleştirilmektedir. Bu eleştirilere yönelik bir çözüm olarak serilerin standartlaştırılması önerilmektedir. Standartlaştırma işlemi, her bir veri noktasından serinin ortalamasının (μ) çıkarılıp standart sapmasına (σ) bölünmesiyle gerçekleştirilmektedir. Bu sayede standartlaştırılmış seri, sıfır ortalamaya ve birim varyansa sahip olur. İndeks, literatürde Döviz Piyasası Baskı İndeksi (Exchange Market Pressure Index

- EMPI) veya Finansal Baskı Endeksi (Financial Pressure Index) olarak da anılmakta ve aşağıda yer alan formül ile hesaplanabilmektedir (Ural ve Balaylar, 2007).

$$FBE = \frac{\left(\frac{\Delta K}{K} \right) - \mu_K}{\sigma_K} + \frac{\left(\frac{\Delta F}{F} \right) - \mu_F}{\sigma_F} - \frac{\left(\frac{\Delta R}{R} \right) - \mu_R}{\sigma_R} \quad (1)$$

Bu çalışmada kriz tanımı yapılırken FBE kullanılmıştır. FBE, döviz kurundaki ve Türk lirası faiz oranlarındaki yükselişler ile brüt rezervlerdeki düşüşler dikkate alınarak oluşturulmuştur. Kriz dönemleri aşağıdaki gibi belirtilmektedir.

Literatürde kriz sinyali veren değişkenler farklılık gösterirken, FBE için belirlenen eşik değerler de çalışmadan çalışmaya değişmektedir. Örneğin, Eichengreen vd.'nden (1996) farklı olarak Kaminsky vd. (1998) eşik değer için ortalamaya 3 standart sapma kullanırken, Edison (2000) bu değeri 2.5 standart sapma olarak belirlemiştir. Bu çalışmada ise 2.5 standart sapma ile elde edilen kriz dönemlerinin Türkiye'deki bilinen kriz ve ekonomik sıkıntı dönemleriyle örtüşmesi nedeniyle bu eşik değer tercih edilmiştir.


Çalışmanın bu bölümünde, 2004 yılından itibaren Türkiye'deki finansal kriz dönemleri, eşitlik 1'deki FBE oluşturularak ve aşağıda sunulan eşik değer bilgisi dikkate alınarak tespit edilmiştir.

$$\begin{aligned} FBE &\geq (\mu + 2.5\sigma) \rightarrow \text{Kriz Durumu (Kriz var)} \\ FBE &\leq (\mu + 2.5\sigma) \rightarrow \text{Kriz Olmama Durumu (Kriz yok)} \end{aligned}$$

Şekil 2'de Türkiye için hesaplanan FBE'nin 2004-2024 yılları arasındaki seyri ve eşik olarak seçtiğimiz 2.5 standart sapma üzerine geçtiği dönemler yer almaktadır. Grafikte sunulan FBE'nin eşik değeri, krizi tanımlamada kullanılan FBE'nin standart sapmasının (2.00073) 2.5 katı (5.0018) olarak belirlenmiştir. Buna göre, endeks bu eşik değeri (5.0018) aştığında kriz durumu (1), aşmadığı dönemlerde ise kriz olmayan durum (0) olarak tanımlanmıştır. FBE sonuçlarına dayanılarak tespit edilen kriz dönemleri Tablo 2'de sunulmaktadır.

İncelenen dönemde FBE ile Türkiye için saptanan kriz dönemleri değerlendirildiğinde, küresel finans tarihinin ilk büyük krizi olan 2008 finansal krizi, önce gelişmiş ekonomileri, sonrasında ise Türkiye gibi gelişmekte olan ülkeleri olumsuz yönde derinlemesine etkilemiştir. Bu krizin etkisiyle Türkiye ekonomisindeki yüksek büyüme hızları yavaşlamış ve 2009 yılında negatif büyüme kaydedilmiştir. Her ne kadar 2008 finansal krizi genel olarak tüm ekonomilerin büyüme oranlarını menfi etkilemiş olsa da ekonomik daralmanın şiddeti Avrupa ülkelerinde ve Türkiye'de daha belirgin şekilde gözlemlenmiştir. Kriz, özellikle gelişmekte olan piyasalara yönelik sermaye akışındaki azalmalar sebebiyle bu ekonomilerde hissedilir düzeyde etkili olmuştur. Covid-19 krizi ise Türkiye ekonomisinde önce enflasyonist baskılar meydana getirmiş, akabinde döviz kurlarında yükselişe yol açmıştır. Benzer döviz kuru baskıları daha önce 2018 Brunson krizi, 2013 FED'in parasal sıkılaştırma beklentisi ve 2008 küresel krizi gibi zaman dilimlerinde de görülmüştür. 2018 Ağustos ayında Dolar/TL kurundaki %33'lük artış ve eş zamanlı TCMB rezervlerindeki azalma, FBE verilerinde en bariz artış olarak kayıtlara geçmiştir. FBE'nin eşik değerini aştığı dönemler, Türkiye ekonomisinin kur ataklarına maruz kaldığı ve uluslararası rezervlerde düşüşlerin yaşandığı zaman aralıklarıyla örtüşmektedir. Pandemi sonrası uygulanan negatif reel faiz politikası döviz kuru baskı endeksini yukarı yönde etkilerken 2023 yılı ortalarından itibaren uygulanan faiz artırımları ve görece iyiye giden ekonomik göstergeler bu endekste bir gerileme sağlamıştır.

Şekil 2. 2004-2024 Dönemi için FBE ile Belirlenen Finansal Krizler



Tablo 2. FBE ile Belirlenen Kriz Dönemleri

Kriz Dönemi	FBE
10-2008	5,8725
06-2018	5,1325
08-2018	5,6599
09-2018	7,0748
08-2020	5,1397
12-2021	9,4886
05-2023	5,3337
06-2023	5,2092

4.2. Rassal Orman

Rassal orman, makine öğrenimi alanında, özellikle sınıflandırma ve regresyon görevlerinde yaygın olarak kullanılan etkili bir yöntemdir. Bu algoritmanın başarısı, örneklem ve özellik seçiminde uyguladığı rassallık prensibine dayanmakta olup bu sayede aşırı öğrenme sorunu azaltılmaktadır ve modelin genelleme performansı iyileşir. Çok sayıda karar ağacından oluşması, modeli gürültülü verilere karşı daha dirençli hale getirir. Ayrıca, özellik önemini belirlemede de kullanılabilen bu yöntem, yüksek boyutlu veri setlerinde dahi başarılı sonuçlar sunar. Ölçeklenebilir yapısı, büyük veri kümelerinde uygulanması açısından önemli bir avantaj sağlarken hem sayısal hem de kategorik verilerle çalışabilme özelliği uygulama alanlarının çeşitliliğini artırmaktadır. Bu nitelikleri sayesinde Rassal orman algoritması, çeşitli disiplinlerde başarılı bir şekilde kullanılmaktadır.

Rassal ormanlar, çok sayıda karar ağacının eş zamanlı olarak eğitilmesi prensibine dayanır ve sınıflandırma problemlerinde model tahmini, çoğunluk oylaması yöntemiyle gerçekleştirilir (Liaw ve Wiener, 2002; Cutler vd., 2012). Algoritmanın temel adımları şunlardır:

1. Eğitim verisinden bootstrap tekniği ile belirlenen sayıda (ntree) örneklem oluşturularak her bir örneklem için bir karar ağacı inşa edilir.
2. Her bir bootstrap örneğine ait ağacın her düğümünde, mevcut p adet öznitelik değişkeni arasından rassal m adet öznitelik değişkeni (mtry) seçilir ve bu m değişken arasından en iyi dallanmayı sağlayacak değişken belirlenir.

$$m = \sqrt{p} \quad (2)$$

3. Oluşturulan n adet karar ağacının ayrı ayrı gerçekleştirdiği tahminler bir araya getirilerek, sınıflandırma problemi için çoğunluk oylaması esasına göre nihai model tahmini yapılır. Ağaç topluluğunun çıktısı $\{T_b\}_1^B$ ve b. rassal ormanın sınıf tahmini olmak üzere yeni bir x noktasında OOB (Out of Bag) tahmini aşağıdaki gibi hesaplanır.

$$\hat{C}_{rf}^B(x) = \text{çoğunluk oylaması } \{\hat{C}_b(x)\}_1^B \quad (3)$$

Bu bilgiler ışığında genelleştirilmiş hata veya OOB hata oranı şu şekilde elde edilir:

$$E_{OOB} = \frac{1}{N} \sum_{i=1}^N I(Y_i \neq \hat{C}_{rf}^B(x)) \quad (4)$$

Rassal orman algoritmasında değişkenlerin önem düzeylerinin belirlenmesi kritik bir aşamadır. Değişken önemliliğini saptamada kullanılan en basit ve etkili yaklaşımlardan biri permütasyon tabanlı yöntemdir. Permütasyon tabanlı değişken önemliliğinin temel adımları şu şekilde sıralanabilir (Genuer vd., 2010; Cutler vd., 2012; Lee vd., 2020):

- Tek bir ağaç için OOB hata oranı hesaplanır (E_{OOB} veya MSE_{OOB}) ve bu değer Err_{OOB_t} ile gösterilir.

OOB_t Örnekleminde X^j değişkeninin gözlem değerleri rassal olarak değişir veya karıştırılır ve bu değer $\overline{OOB}_t^j$ ile gösterilir. Daha sonra $\overline{OOB}_t^j$ değerinin hatası hesaplanır ve bu $Err\overline{OOB}_t^j$ ile gösterilir. Bu işlemler tüm bootstrap örneklemeleri için tekrar edilir. X^j değişkeninin önemi $VI(X^j)$ ile gösterilir ve aşağıdaki gibi hesaplanır.

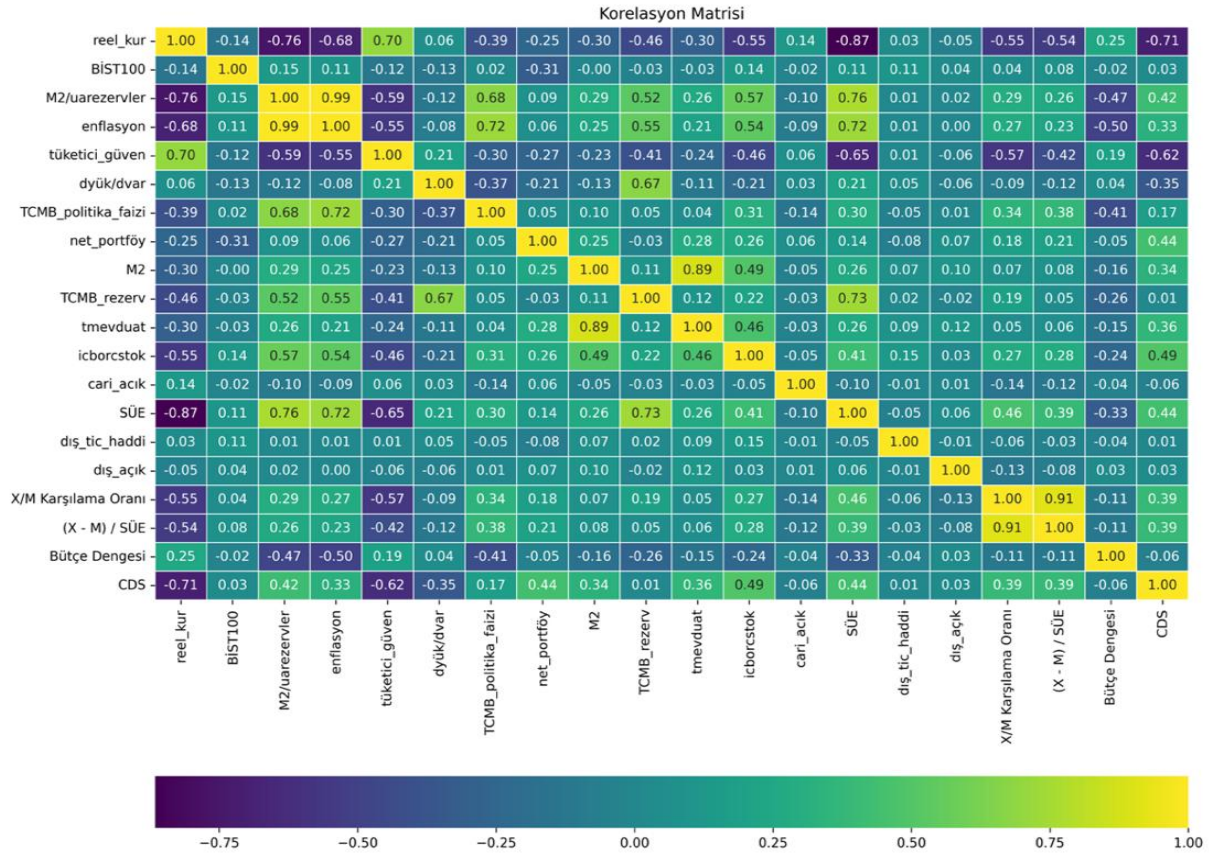
$$VI(X^j) = \frac{1}{ntree} \sum (Err\overline{OOB}_t^j - Err_{OOB_t}) \quad (5)$$

Bir değişkenin rassal permütasyonlarından kaynaklanan hata miktarındaki artış ne kadar yüksek ise ilgili değişkenin modeldeki önemi de o kadar fazladır. Aksine, permütasyonların hata üzerinde minimal veya sıfır etkisi olması durumunda, söz konusu değişkenin model için önemsiz olduğu değerlendirilir (Bayram Arlı vd., 2022).

5. Analiz ve Bulgular

Makine öğrenimi uygulamasına başlamadan önce, Türkiye'deki finansal kriz dönemlerini tahmin etmek için kullanılan öncü göstergeler arasındaki korelasyon değerleri incelenmiştir. Şekil 3'te yapılan analiz sonucunda, geniş para arzının uluslararası rezervlere oranı ile enflasyon değişkeni arasındaki korelasyon değeri 0.986034, ihracatın ithalatı karşılama oranı ile dış açığın sanayi üretim endeksine oranı arasındaki korelasyon değeri ise 0.913845 olarak hesaplanmıştır. Belirlenen 0.90 eşik değeri ve üzerindeki korelasyona sahip değişkenler ($M2/uarezervler$ ve $(X-M)/SÜE$) öncü göstergeler arasından çıkarılarak analize devam edilmiştir.

Şekil 3. Öncü Göstergeler Arasındaki Korelasyon Değerleri



5.1. LazyPredict ile Model Değerlendirme

LazyPredict, temel makine öğrenimi algoritmalarını içeren çeşitli modellerin kolaylıkla oluşturulmasına ve performanslarının karşılaştırılmasına olanak tanıyan bir kütüphanedir (Shankarpandala, 2024). Parametre optimizasyonuna ihtiyaç duymadan, birkaç satır kod ile farklı modellerin denenmesine imkân vermesi, LazyPredict'in önemli bir özelliğidir. Bu çalışmada, veri analizi kütüphanesindeki 26 farklı sınıflandırıcı modelinin performansı LazyPredict kütüphanesindeki LazyClassifier aracıyla karşılaştırılmıştır. Bu sayede modeller hakkında ön bilgi edinilmiş ve en yüksek genel doğruluğa sahip olan Rassal orman algoritması yöntemi belirlenmiştir. Ardından, belirlenen bu yöntemin optimum hiperparametre değerleri özgün kodlarla saptanarak model yeniden uygulanmıştır. Lazypredict ile elde edilen Rassal orman doğruluk oranı sonuçları Tablo 3'te yer almaktadır. Bu çalışma, makine öğrenimi model seçimi ve optimizasyon süreçlerine sistematik bir yaklaşım sunmayı amaçlamaktadır.

Tablo 3. LazyPredict Rassal Orman Tahmin Sonuçları

RandomForestClassifier	
Accuracy	0,941176
F1 Score	0,912656
Time Taken	0,208502

5.2. Rassal Orman Uygulama Sonuçları

İncelenen dönemde Türkiye'de finansal krizlerin varlığını öngörebilmek amacıyla veri seti, öncelikle %80'i eğitim ve %20'si test verisi olacak şekilde rassal olarak ikiye ayrılmıştır. Bağımlı değişkenin ekonomideki kriz durumunu "Kriz Var" ve "Kriz Yok" şeklinde iki kategoriyle ifade ettiği sınıflandırma ağacı, Breiman vd. (1984) tarafından sunulan metodolojik çerçeveye uygun olarak oluşturulmuştur.

Tablo 4. Random Forest Modeline Ait Performans ve Doğrulama Sonuçları

Değerlendirme Kriteri	Değer (%)
Eğitim Doğruluğu (Train Accuracy)	98,5
Test Doğruluğu (Test Accuracy)	88,23
CV Doğruluğu (10-Fold Mean Accuracy)	90,86
CV Standart Sapma	5,40

Tablo 4'te yer alan verilere göre, modelin eğitim verisine olan doğruluğu oldukça yüksek (%98,5) olmakla birlikte, 10 katlı çapraz doğrulama sonucu elde edilen ortalama doğruluk değeri (%90,86), test doğruluğu ile oldukça uyumlu olup modelin genel başarımlı düzeyinin yüksek ve tutarlı olduğunu göstermektedir. Çapraz doğrulama standart sapmasının %5,40 düzeyinde olması ise modelin farklı veri alt kümelerinde benzer performans gösterdiğini ve varyansın kabul edilebilir sınırlar içinde olduğunu ortaya koymaktadır.

Tablo 5, Türkiye'de finansal kriz dönemi tahmininde Rassal orman algoritması için en iyi hiperparametreleri göstermektedir. Bu parametrelerin her biri, modelin öğrenme sürecini ve nihai yapısını şekillendiren kritik ayarlardır. "criterion" parametresi, karar ağaçlarında dallanma kalitesini ölçmek için kullanılan Gini kriterini ifade etmektedir. Gini, düğümdeki veri noktalarının homojenliğini ölçmekte ve algoritma dallanma sonucunda Gini kirliliğini en aza indirmeye çalışmaktadır. "max_depth", karar ağaçlarının maksimum derinliğini sınırlandırarak aşırı öğrenmeyi engellemeyi amaçlamaktadır. 10 değeri, sapma-varyans dengesi açısından uygun bir karmaşıklık seviyesini temsil etmektedir. "max_features", her düğümde değerlendirilecek maksimum özellik sayısını belirterek ağaçlar arasındaki korelasyonu azaltır ve modelin genelleme yeteneğini artırmaktadır. 5 değeri, her dallanma noktasında rastgele seçilen özellikler arasından en iyi ayrımı sağlayan özelliğin seçilmesini sağlamaktadır. "min_samples_split", bir iç düğümün dallanabilmesi için gerekli minimum örnek sayısını tanımlamaktadır. 5 değeri, ağaçların detaylı dallanmasına olanak tanıyarak verideki ince ayrımların yakalanmasını sağlamaktadır. "n_estimators" ise rassal orman modelindeki toplam karar ağacı sayısını ifade etmektedir. 100 değeri, performans ve hesaplama verimliliği arasında uygun bir denge sağlayarak modelin varyansını azaltmaktadır.

Tablo 5. Model İyileştirme Sonrası En İyi Parametreler

En İyi Parametreler	
criterion	gini
max_depth	10
max_features	5
min_samples_split	5
n_estimators	100

Makine öğrenmesinde değerlendirme ölçütleri, modellerin başarısını anlamak ve kıyaslamak için önemli bir rol oynamaktadır. Bu çalışmada, Rassal orman algoritmasının performansını değerlendirmek amacıyla "Doğruluk Oranı", "Kesinlik", "Duyarlılık", "Özgüllük", "F1 Puanı" ve "AUC Değeri" gibi çeşitli ölçütler kullanılmıştır. Veri setinin eğitim ve test kümelerine ayrılmasıyla Rassal orman modeli çok sayıda ağaç oluşturarak kriz dönemlerine dair tahminlerde bulunmakta ve bu tahminler test kümesiyle karşılaştırılmaktadır. Bu nedenle kullanılan metrikler Rassal orman modelinin analizdeki tahmin kalitesini temsil etmektedir. Bu metrikler aracılığıyla oluşturulan Tablo 6, makroekonomik ve finansal öncü göstergelerle Türkiye'de kriz dönemi tahminlemesinde kullanılan Rassal orman modelinin tahmin gücünü sergilemektedir.


Rassal orman modeli, Türkiye'de finansal kriz dönemi tahminlemesinde yüksek bir performans sergilemektedir. Modelin doğruluk oranının %92.16, kesinliğinin %93.10 ve F1 puanının 0.9153 olması, modelin, krizleri doğru sınıflandırma konusunda başarılı olduğunu gösterirken %90 duyarlılık ve %1 özgüllük oranları ise sırasıyla krizleri yakalama ve yanlış alarm üretmeme yeteneğinin güçlü olduğunu ortaya koymaktadır. Ayrıca, 0.9971'lik AUC değeri, modelin kriz ve kriz dışı dönemleri ayırma konusunda mükemmele yakın bir başarıya sahip olduğunu desteklemektedir.

Tablo 6. Rassal Orman Modeli Tahmin Performans Sonuçları

Ölçüt	Değer
Doğruluk	0.9216
Kesinlik	0.9310
Duyarlılık	0.9000
Özgüllük	1.0000
F1 Puanı	0.9153
AUC	0.9971

Şekil 4, incelenen dönemde Türkiye'deki finansal kriz tahminlemesinde Rassal orman algoritmasının sonuçlarına ait ROC eğrisini ve karmaşıklık matrisini sunmaktadır. ROC eğrisinin sol üst köşeye yakın seyretmesi ve buna eşlik eden 0.9971'lik yüksek AUC değeri, modelin mükemmele yakın bir sınıflandırma performansına sahip olduğunu belirtirken karmaşıklık matrisi ise modelin kriz tahmin performansının detaylı bir dökümünü göstermektedir. Matris, gerçekleşen krizlerin %92.86'sının doğru bir şekilde "kriz" olarak tahmin edildiğini gösterirken, gerçekte kriz olmayan dönemlerin %100'ünün doğru bir şekilde "kriz değil" olarak sınıflandırıldığını ortaya koymaktadır. Bu durum, modelin hem krizleri yakalama (duyarlılık) hem de yanlış alarm üretmeme (özgüllük) konusunda oldukça başarılı olduğunu ve güvenilir tahminler sağladığını göstermektedir.

Şekil 4. Kriz Tahminlemesinde ROC Eğrisi ve Karmaşıklık Matrisi



Tablo 7'de Türkiye'deki finansal kriz dönemlerini tahminlemede kullanılan Rassal orman algoritmasındaki öncü göstergelerin önem düzeyleri sayısal değerleriyle sunulmaktadır. Bu göstergelerin önem düzeyleri, kriz tahmini açısından hangi göstergenin daha belirleyici olduğunu ortaya koyarak kriz riskini anlamada en etkili olan göstergeleri sıralayarak modelin nasıl çalıştığına dair önemli ipuçları sağlamaktadır. Modelin kriz sınıflandırması yaparken hangi değişkenlere daha fazla ağırlık verdiğini gösteren bu önem sıralaması, makroekonomik kırılganlıkların kaynakları hakkında değerli bilgiler içermektedir.

Tablo 7. Potansiyel Kriz Tahminleri Önem Oranları

Öncü Göstergeler	Önem Düzeyleri
reel_kur	0.094443
cari_acık	0.087468
dış_açık	0.086719
M2	0.075605
tmevduat	0.073585
CDS	0.066184
tüketici_güven	0.063449
SÜE	0.052957
BİST100	0.052574
icborcstok	0.052309
TCMB_rezerv	0.050925
enflasyon	0.050377
dyük/dvar	0.049141
X/M Karşılama Oranı	0.043495
dış_tic_haddi	0.043071
net_portföy	0.022461
tcmb_politika_faizi	0.019198
Bütçe Dengesi	0.016039

Tabloda görüldüğü üzere, Rassal orman algoritması sonuçlarına göre, reel efektif döviz kuru (reel_kur) %9.44'lük önem düzeyiyle kriz tahminlemesinde en belirleyici öncü gösterge olarak öne çıkmaktadır. Bu bulgu, özellikle Türkiye gibi gelişmekte olan piyasalarda reel kurdaki aşırı değerlenme veya oynaklığın, rekabet gücü kaybı, dış dengesizliklerin derinleşmesi ve ani kur düzeltmeleri yoluyla

bilançolar üzerinde yarattığı tahribat nedeniyle finansal krizlerin tetiklenmesindeki merkezi rolünü vurgulayan literatürle (Kaminsky ve Reinhart., 1999; Obstfeld, 1995) tam bir uyum içindedir. Aynı zamanda bu sonuç reel efektif döviz kurunun para krizlerini açıklamada başarılı olduğunu tespit eden Altıntaş ve Öz (2007) tarafından yapılan çalışma sonuçlarıyla uyumludur. Reel efektif döviz kuru endeksi, ulusal paranın yabancı paralar karşısındaki göreceli değerini göstermesi açısından önemli bir öncü gösterge olarak kabul edilmektedir (Çakmak, 2013). Sonuçlarımızla uyumlu olarak Dornbusch (2002), bir ülke parasının yüzde yirmi beş oranında reel değer kazanmasının krize yol açabileceğini belirtmektedir.

Reel efektif kurun artışı TL'nin reel olarak değer kazandığını, diğer bir deyişle Türk mallarının yabancı mallar cinsinden fiyatının arttığını göstermektedir. Bu durum ise ihracatı zorlaştırarak azaltmakta, ithalatı ise daha cazip hale getirerek artırmaktadır. Bunun sonucu olarak dış ticaret açığı ve cari işlemler açığı finanse edilmesi gereken şekilde artabilir. Eğer bu finansman, doğrudan yatırımlar gibi istikrarlı kaynaklar yerine, kısa vadeli sermaye girişleriyle sağlanırsa, ülke ekonomisi dış şoklara ve sermaye çıkışlarına karşı daha kırılgan hale gelmektedir. Bu sermayenin ilerleyen dönemlerde aniden çıkması ise kur şoklarına ve finansal krize yol açabilmektedir. Borçlanma cazibesi ve riskler açısından bakıldığında ise TL'nin değerli olması, dışarıdan dövizle borçlanmayı daha cazip gösterebilir. Ancak ileride kurun ani bir şekilde düşmesi (TL'nin değer kaybetmesi) durumunda, döviz cinsinden borçların TL karşılığı aniden artarak şirketler ve devlet için ciddi bir borç yükü oluşturabilir ve bu da krizi tetikleyebilir.

Reel kuru takiben, cari işlemler açığı (cari_acık) ve dış ticaret açığı (dış_açık) model tarafından ikinci ve üçüncü en önemli değişkenler olarak sıralanmıştır. Bu durum, dış dengesizliklerin ve özellikle bu açıkların finansman ihtiyacının, sürdürülebilirliği ve finansman kalitesinin Türkiye'de kriz kırılganlıklarının temel belirleyicilerinden olduğunu kuvvetle teyit etmektedir (Milesi-Ferretti ve Razin, 1996). Türkiye'de 2003 sonrası dönemde belirginleşen net dış kaynak girişi, Türkiye Cumhuriyet Merkez Bankası (TCMB) döviz rezervlerinde artış sağlamıştır. Bu durum ve diğer ilgili gelişmeler neticesinde Türk Lirası (TL), ABD Doları karşısında değer kazanmış, dolayısıyla dolar cinsinden bir mal veya hizmet almak için gereken TL miktarı reel olarak azalmıştır. Teorik beklentilere paralel olarak bu gelişme, cari açığın ve onun temel bileşeni olan dış ticaret açığının rekor seviyelere ulaşmasına neden olmuştur.

Dış denge göstergelerinin ardından, parasal ve finansal değişkenler önem kazanmaktadır. M2 para arzı ve bankacılık sistemindeki toplam mevduatlar (tmevduat) yüksek öneme sahip bulunmuştur. Para arzındaki hızlı artışlar, yaygın olarak kredi genişlemesi ve aşırı ısınma dönemleriyle ilişkilendirilmekte olup bu durum finansal istikrarsızlık ve kriz olasılığını artırabilmektedir. Mevduat hareketleri ise finansal sistemdeki güven ve likidite durumunu yansıtabilir (Demirgüç-Kunt ve Detragiache, 1998). Modelin bu iki değişkene attığı yüksek önem, Türkiye ekonomisi özelinde de kur ve para/kredi dinamiklerinin kriz mekanizmalarında merkezi bir rol üstlendiğini desteklemektedir. Bu değişkenleri takiben, piyasa bazlı risk algısının önemli bir göstergesi olan CDS primi (CDS) de benzer şekilde yüksek bir önem düzeyine sahiptir; bu, piyasa beklentilerinin ve risk fiyatlamasının kriz tahmininde ne kadar kritik olduğunu göstermektedir. Toplam mevduatlardaki değişimler, bankacılık sisteminin sağlığı, likidite koşulları ve genel güven ortamı hakkında sinyaller verirken CDS primi ise piyasanın ülke risk algısını doğrudan yansıtan ve kriz beklentilerini ölçen kritik bir göstergedir (Longstaff vd., 2011). Bu grubun yüksek önemi, dış denge sorunları, finansal sektör sağlığı ve piyasa risk algısının kriz tahmininde belirleyici olduğunu göstermektedir. Finansal sıkıntının yükselmesi genel ekonomik görünümde ve varlık fiyatlarında belirsizlik artışı ile volatiliteye sebep olabilmektedir. Nitekim, yabancı döviz piyasası ise finansal baskıdan etkilenen piyasalardan ve de finansal sıkıntının sebeplerinden biridir. Finansal sıkıntının bir diğer kaynağı, kamu sektörünün yüksek borçlanma seviyesidir. Aynı zamanda Türkiye'nin kredi risk priminin (CDS) yüksekliği de borçların çevrilme maliyetini artırabilmektedir. Bu göstergeleri tüketici güven endeksi, sanayi üretim endeksi takip etmektedir.

Sanayi üretimi ve tüketici güveni reel ekonomideki yavaşlamaları ve hane halkı beklentilerindeki bozulmaları yansıtarak kriz öncesi sinyaller üretebilir.

Finansal piyasa göstergesi olan BİST100 endeksi de benzer bir önem düzeyindedir; borsadaki sert düşüşler genellikle krizlerle ilişkilendirilir. Hisse senedi fiyatlarının kriz öncü göstergesi olarak değerlendirilmesinin temel nedeni, kriz öncesi dönemlerde görülebilen aşırı yükselişler ve bu balonların patlamasıyla finansal sistemde ortaya çıkan dengesizliklerdir. Bu duruma örnek olarak 1929 Bunalımı ve 2007-2008 Mortgage Krizi öncesinde ABD borsasındaki hızlı yükselişle oluşan spekülasyon menkul kıymetler balonu gösterilebilir. Borsa endeksi finansal krizlerin temel göstergelerinden biri olarak kabul edildiğinden, bu çalışmada Türkiye için BİST100 endeksi de modellemeye bağımsız değişken olarak dahil edilmiştir. Bu değişkenlerin modeldeki orta düzey önemi, reel ekonomik aktivite, güven, temel makro göstergeler ve finansal piyasa hareketlerinin de kriz dinamiklerinde rol oynadığını ancak ilk gruptakiler kadar baskın olmayabileceğini düşündürmektedir.

Makroekonomik temellerden iç borç stoku (icborcstok), TCMB rezervleri (TCMB_rezerv) ve enflasyon (enflasyon) da makroekonomik istikrarsızlık ve politika yönetimiyle ilgili riskleri işaret eder (Fischer vd., 2002). Merkez bankası rezervleri, dış şoklara karşı bir tampon görevi görmektedir ve yetersizliği önemli bir kırılganlık göstergesidir (Obstfeld, 1995).

Grafiğin alt sıralarında ise ülkenin dış pozisyonuyla ilgili diğer göstergeler (net dış yükümlülüklerin varlıklara oranı (dyük / dvar), ihracatın ithalatı karşılama oranı (X / M Karşılama Oranı), dış ticaret hadleri (dış_tic_haddi)) bulunmaktadır. Bu değişkenler teorik olarak önemli olsa da (Lane ve Milesi-Ferretti, 2007), modelin bu bilgileri daha çok ana dış denge açıkları veya reel kur üzerinden yakaladığı anlaşılmaktadır. İhracatın ithalatı karşılama oranı ve dış ticaret hadleri dış dengeyle ilgili olsa da model muhtemelen bu bilgiyi cari_acık gibi daha kapsamlı değişkenlerden elde etmektedir. Bütçe dengesi ve politika faizi gibi politika değişkenlerinin ve net portföy yatırımlarının görece olarak daha az önemli bulunması, modelin krizleri tetikleyen temel makroekonomik dengesizliklere ve risk algılarına daha fazla odaklandığını veya bu politika değişkenlerinin etkisinin diğer göstergeler aracılığıyla dolaylı olarak yakalandığını gösterebilir.

Sonuç olarak, Rassal orman modelinin değişken önem analizi, Türkiye'deki finansal krizlerin öngörülmesinde reel kur hareketleri, parasal genişleme, dış açıklar, finansal sektör göstergeleri ve piyasa risk algısının en etkili faktörler olduğunu göstermektedir. Reel ekonomi, enflasyon, rezervler ve iç borç gibi diğer makroekonomik değişkenler de önem arz etmekle birlikte, modelin karar alma sürecinde daha tali bir rol üstlenmektedir. Bu sonuçlar, kriz önleme stratejileri ve EWS oluşturulurken hangi alanlara öncelik verilmesi gerektiği konusunda değerli bilgiler sunmaktadır.

5.3. Kısmi Bağımlılık Grafikleri

Şekil 5'te yer alan grafikler finansal krizler için erken uyarı sinyali sayılabilecek her bir öncü gösterge ile Türkiye'de finansal kriz dönemlerini tahmin etmede rassal orman modelinin öngördüğü "kriz" olasılığı arasındaki ilişkiyi gösteren bir kısmi bağımlılık grafiğidir (PDP). Her bir öncü gösterge için elde edilen PDP, Rassal orman modelinin öngördüğü "kriz" olasılığı ile değişken arasındaki marjinal ilişkiyi, diğer tüm değişkenlerin ortalama etkisi sabit tutulduğunda göstermektedir.


Göstergenin değeri arttıkça kriz olasılığının azaldığı değişkenler arasında reel efektif döviz kuru bulunmaktadır. Grafikte reel kur seviyesi ile modelin tahmin ettiği kriz olasılığı arasında belirgin, kademeli düşüşler gösteren ve genel olarak ters yönlü bir ilişki olduğu görülmektedir. Literatürde genellikle, özellikle gelişmekte olan ülkeler için, reel kurun aşırı değerlenmesinin (yüksek reel kur) uluslararası rekabet gücünü azaltarak cari işlemler açığını artırdığı, ekonomiyi sıcak para olarak tabir edilen oynak sermaye akımlarına bağımlı hale getirdiği ve ani duruş (sudden stop) veya kur krizi riskini artırdığı vurgulanır (Obstfeld ve Rogoff, 1996; Kaminsky, Lizondo, ve Reinhart, 1998; Rodrik, 2008). Bu


çerçevede, krizlerin genellikle reel kurdaki aşırı değerlenme dönemlerini takiben yaşanacak ani değer kayıpları ile tetiklendiği beklenir. İncelenen 2004-2024 döneminde, TL'nin reel olarak değerli olduğu zaman dilimleri, eş zamanlı olarak bu döneme eşlik eden diğer makroekonomik koşulların — örneğin yüksek sermaye girişi, artan döviz rezervleri veya düşük borçlanma maliyetleri gibi — modele dolaylı olarak yansıyan etkileriyle şekillenmiş olabilir. Model, kriz olasılığını düşüren bu diğer faktörlerin etkisini, yüksek reel kur ile ilişkilendirmiş olabilir. Bu bulgu, standart teorik beklentilerle çelişiyor gibi görünse de modelin yakaladığı karmaşık korelasyonlar, gecikmeli etkiler veya döneme özgü faktörlerle açıklanabilir. Öte yandan, modelin tahmin mekanizması, kısa vadede reel kur değerlenmesinin istikrar göstergesi olarak yorumlandığı dönemleri kriz riski düşük olarak değerlendirmiş olabilir. Ancak bu durum, reel kurdaki aşırı değerlenmenin orta ve uzun vadede dış denge bozulması, rekabet gücü kaybı ve ani portföy çıkışları yoluyla kriz riskini yeniden yükseltebileceği gerçeğini değiştirmemektedir. Dolayısıyla, bu bulgunun yorumlanmasında, reel kurdaki aşırı değerlenmenin orta-uzun vadede finansal kırılganlıkları artırabileceği ve ani şoklara karşı direnci azaltabileceği yönündeki temel iktisadi prensip göz ardı edilmemelidir; modelin bu dönemdeki eş anlı pozitif şokları birincil etken olarak değerlendirdiği kabul edilmelidir. Bu bağlamda, modelin reel kur üzerindeki tahminsel tepkisi, sadece reel kur seviyesine değil, aynı zamanda bu değişkenin eşlik ettiği iktisadi bağlama göre şekillenen dinamik bir ilişkiyi yansıtıyor olabilir.

Kriz olasılığı ile negatif ilişkisi olan bir diğer öncü gösterge TCMB rezervleridir. Rezervler azaldıkça (özellikle 60 milyar USD altı) risk artmakta, yeterli rezerv seviyeleri (örn. 90-100 milyar USD üzeri) ise en düşük riskle ilişkilidir. Bu, rezervlerin dış şoklara karşı tampon rolünü vurgulayan literatürle (Kaminsky vd., 1998; Jeanne ve Rancière, 2011) tamamen uyumludur. Benzer şekilde güven endeksi düştükçe kriz olasılığı keskin bir şekilde artmaktadır (Santero ve Westerlund, 1996). Yine bütçe açığı azaldıkça veya fazla verdikçe kriz olasılığı düşmektedir. Bu, mali disiplinin finansal istikrarı desteklediği ve kriz riskini azalttığı yönündeki genel görüşle (Easterly ve Rebelo, 1993; Catao ve Terrones, 2005) uyumludur.

Türkiye için 2004-2024 dönemi verileriyle oluşturulan Rassal orman (Random forest) modelinden elde edilen PDP grafiklerine göre değişken değeri ile kriz olasılığı arasında pozitif ilişki bulunan göstergeler arasında politika faizi bulunmaktadır. Faiz oranı yükseldikçe modelin öngördüğü kriz olasılığı da artmaktadır. Bu durum, faiz artışlarının genellikle mevcut istikrarsızlığa bir tepki olması (Kaminsky vd., 1998), yüksek faizlerin ekonomik maliyetleri veya politika ikilemleri (Calvo ve Reinhart, 2002) gibi faktörlerle açıklanabilir ve faizin kriz dinamiklerindeki karmaşık rolünü yansıtabilir. Düşük faiz oranları (<%8) en düşük riskle ilişkiliyken, faiz oranı arttıkça (%25-30 üzerinde en yüksek seviyeye ulaşarak) öngörülen kriz olasılığı da kademeli olarak yükselmektedir. İlk bakışta para politikasının istikrar sağlayıcı rolüyle çelişkili görünen bu bulgu, kriz dinamikleri çerçevesinde açıklanabilir. Yüksek faiz oranları, genellikle merkez bankalarının mevcut veya beklenen istikrarsızlıklara (yüksek enflasyon, kur baskısı, sermaye çıkışları gibi) verdiği bir *tepki* olabilir (Kaminsky vd., 1998) ve bu nedenle artmış olan kriz riskiyle korelasyon gösterebilir. Ayrıca, özellikle "ani duruş" gibi senaryolarda karşılaşılan politika ikilemleri (Calvo ve Reinhart, 2002) veya yüksek borçlanma maliyetlerinin ekonomi üzerindeki kaçınılmaz olumsuz etkileri de bu ilişkiyi açıklayabilir. Politika faizinin modeldeki genel öneminin nispeten düşük olması da dikkate alındığında, PDP'de gözlenen bu pozitif ilişkinin, faizin krizleri tetikleyen ana faktör olmasından ziyade, kriz ortamına eşlik eden veya krize verilen tepkisel bir unsuru yansıttığı değerlendirilebilir. Benzer şekilde göstergenin değeri arttıkça kriz olasılığının arttığı değişkenler arasında toplam mevduatlar, iç borç stoğu, CDS primi, dış yükümlülüklerin dış varlıkları oranı yer almaktadır. Sebepleri arasında aşırı mevduat birikiminin bankacılık sektöründe potansiyel riskler yaratabileceği, artan iç borçun mali baskıları ve kırılganlıkları artırarak kriz riskini yükseltebileceği düşünülmektedir. Net dış yükümlülüklerin artması ise dış kırılganlığı artırır ve bu sonuç ülkenin dış finansman koşullarındaki değişimlere veya şoklara karşı daha hassas hale geldiğini gösteren literatürle (Lane ve Milesi-Ferretti, 2007) uyumludur.

Şekil 5. Öncü Göstergeler Kısmi Bağımlılık Grafikleri





Cari açık ve dış ticaret açığını temsil eden her iki grafik de dış dengesizlikler ile kriz riski arasında güçlü ve belirgin eşik etkileri (threshold effects) içeren non-lineer (doğrusal olmayan) ilişkiler olduğunu göstermektedir. Literatür, genellikle büyük dış ticaret açıklarıyla birlikte seyreden büyük cari işlemler açıklarının ülkeleri dış finansmana bağımlı hale getirdiğini, küresel likidite koşullarındaki ve yatırımcı duyarlılığındaki değişimlere karşı kırılganlığı artırdığını ve ani sermaye çıkışları (sudden stops) riskini yükselterek finansal krizlere zemin hazırladığını vurgulamaktadır (Aydın, 2022). PDP grafiklerine göre kriz olasılığı ile doğrusal olmayan ilişki gözlemlenen göstergelerden bir diğeri para arzıdır. Farklı M2 seviyelerinde kriz olasılığı düşmekte veya artmaktadır. Bu durum, M2'nin kriz riski üzerindeki etkisinin likidite koşulları, finansal istikrar (Greenwood vd., 2022) ve potansiyel varlık balonları (Anderson vd., 2017) gibi faktörlere bağlı olarak değiştiğini ve belirli eşiklerin politika yapımı için önemli olabileceğini göstermektedir.

Borsa getirisi ile kriz olasılığı arasında ise ters U-şeklinde bir ilişki bulunmaktadır; en yüksek risk yatay veya hafif negatif getiri dönemleriyle ilişkiliyken hem belirgin negatif getiriler hem de pozitif getiriler daha düşük riskle ilişkilidir. Bu, en yüksek riskin sert düşüşlerden ziyade belirsizliğin hâkim olduğu durgunluk dönemlerinde öngörüldüğünü göstermektedir. Enflasyon ile kriz olasılığı arasında keskin bir eşik etkisi gözlenmektedir; belirli bir enflasyon seviyesi aşıldığında kriz olasılığı ani bir sıçramayla yükselmekte ve yüksek kalmaktadır. Bu, yüksek enflasyonun artan makroekonomik istikrarsızlık ve kriz riskiyle ilişkili olduğu bulgusunu (Fischer vd., 2002; Calvo ve Reinhart, 2002) desteklemektedir. Doğrusal olmayan ilişki gözlemlenen bir diğer öncü gösterge ise sanayi üretim endeksi olmuştur. Hem düşük üretim seviyeleri (ekonomik daralma sinyali, Kaminsky vd., 1998) hem de çok yüksek üretim seviyeleri (potansiyel aşırı ısınma işareti) artan kriz riski ile ilişkilendirilmiştir.

Sonuç

Bu çalışma, Türkiye ekonomisi için finansal krizlerin erken tespitine yönelik olarak FBE ve rassal orman makine öğrenimi algoritmasını bütünleşik bir yaklaşımla ele almıştır. Finansal krizlerin yüksek sosyo-ekonomik maliyetleri göz önüne alındığında, bu tür krizleri öngörebilmek, özellikle yükselen piyasa ekonomilerinde politika yapıcılar açısından kritik bir öneme sahip olmakla birlikte, zorlu bir süreci de beraberinde getirmektedir.

Araştırmada, rassal orman modeli kullanılarak FBE temelinde kriz dönemlerini tahmin etmede etkili olan makroekonomik ve finansal öncü göstergeler belirlenmiştir. Bu göstergelerin, potansiyel krizlere işaret eden erken uyarı sinyalleri olarak değerlendirilebileceği sonucuna varılmıştır. Çalışmada tespit edilen öncü göstergelerin, Krugman'ın (1979) birinci nesil kriz modelleriyle ortaya koyduğu teorik çerçeve ile uyumlu olduğu görülmüştür. Özellikle, bütçe açıklarının parasal genişleme yoluyla finanse edilmesinin enflasyonist baskı, ödemeler dengesi sorunları, sermaye kaçışı ve nihayetinde döviz kuru üzerindeki baskıyı artırarak krizlere zemin hazırladığı teorik altyapısı, Türkiye özelinde belirlenen göstergelerle desteklenmektedir. Bu bağlamda, 2004-2024 dönemi itibarıyla Türk lirasının reel dış değerindeki belirgin istikrarsızlık, teorik beklentilerle örtüşmektedir.

Öncü göstergeler ile kriz olasılığı arasındaki ilişkinin derinlemesine anlaşılması amacıyla kullanılan kısmi bağımlılık grafikleri, hangi göstergelerin hangi seviyelerde kriz riskini artırdığına dair önemli nicel çıkarımlar sunmuştur. Bu analizler, erken uyarı sistemlerinin kalibrasyonu ve etkinliği açısından değerli bilgiler sunmakta; elde edilen bulgular ise Türkiye'nin olası finansal şoklara karşı direncini

artırmak için politika yapıcılarının önceliklerini gözden geçirmeleri gerektiğini ortaya koymaktadır. Reel döviz kurunun dış ticaret dengesi ve dolayısıyla büyüme, istihdam, enflasyon gibi temel makroekonomik değişkenler üzerindeki kritik etkisi göz önüne alındığında, politika yapıcılarının öncelikle fiyat istikrarını (örneğin, enflasyonu sürdürülebilir biçimde %5 gibi düşük seviyelere çekerek TL'nin iç değerini korumak) ve ardından döviz kuru istikrarını (TL'nin dış değerini korumak) sağlamaya odaklanması gerekmektedir. Daha yapısal bir perspektiften bakıldığında ise, dış finansman ihtiyacını azaltan, ihracat odaklı büyümeyi teşvik eden ve üretimde teknolojik dönüşümü hızlandıran politikalara öncelik verilmesi elzemdir. Ancak, bu tür köklü bir ekonomik dönüşümün başarısı, yalnızca iktisadi tedbirlerle sınırlı kalmayıp, ülkenin daha geniş çaplı, bütünsel bir reform sürecini benimsemesini gerektirmektedir.

Ek olarak, yapay zekâ ve makine öğrenimi tekniklerinin yaygınlaşması, kriz dinamiklerini etkileyen karmaşık değişkenlerin, etkileşimlerin ve kurumlar arası risk bağlantılarının daha etkin bir şekilde modellenmesi ve ölçülmesi için önemli fırsatlar sunmaktadır. Bu teknolojiler, EWS'nin doğruluğunu ve araştırma verimliliğini artırma potansiyeline sahiptir. Bu nedenle, özellikle Türkiye gibi yükselen piyasa ekonomilerinde finansal risk farkındalığının artırılması, erken uyarı mekanizmalarının güçlendirilmesi ve kriz önleme kapasitelerinin geliştirilmesi konularında daha fazla akademik araştırmaya ihtiyaç duyulmaktadır.

Bu çalışmada elde edilen bulguların genellenebilirliğini artırmak amacıyla, müteakip araştırmalarda Türkiye ile benzer yapısal özelliklere sahip diğer gelişmekte olan ülkelerdeki finansal kriz dinamiklerinin de benzer metodolojik çerçevelerle tetkik edilmesi önerilmektedir. Bu bağlamda, makine öğrenmesi alanındaki metodolojik gelişmelerden istifade edilerek farklı sınıflandırma veya tahmin algoritmalarının uygulanması suretiyle elde edilen sonuçların sağlamlığının sınanması ve bulguların teyit edilmesi önem arz etmektedir. Özellikle finansal krizler ile öncü makroekonomik göstergeler arasında sıklıkla gözlemlenen doğrusal olmayan ilişkilerin, geleneksel ekonometrik modellerin varsayımsal kısıtlamalarının ötesine geçebilen makine öğrenmesi yöntemleri aracılığıyla analiz edilmesi, kriz tahminleme sürecinde daha yüksek doğruluk ve esneklik sağlayabilmektedir. Makine öğrenmesi modelleri, çok boyutlu veri yapıları içerisinde karmaşık etkileşimleri ve gizli örüntüleri tespit edebilme kapasitesi sayesinde, parametrik varsayımlara dayanmadan veri odaklı çıkarımlarda bulunabilmekte ve bu yönüyle klasik ekonometrik yaklaşımlara kıyasla daha geniş bir modelleme esnekliği sunmaktadır. Bu tür yöntemlerin kullanımı, gelişmekte olan ülkelerin kriz oluşum mekanizmalarının daha derinlemesine anlaşılmasına ve erken uyarı sistemlerinin daha etkin biçimde geliştirilmesine önemli katkılar sağlayabilir.

Bulgular doğrultusunda, Türkiye'nin finansal kırılganlıklarını azaltmak ve olası ekonomik şoklara karşı direnç kapasitesini artırmak için bütüncül ve proaktif bir politika setine ihtiyaç duyulmaktadır. Öncelikle fiyat istikrarının kalıcı biçimde sağlanması ve döviz kuru oynaklığının azaltılması amacıyla para ve maliye politikalarının eşgüdüm içinde yürütülmesi önem arz etmektedir. Bu çerçevede, Merkez Bankası'nın bağımsızlığının güçlendirilmesi, şeffaf iletişim stratejilerinin benimsenmesi ve mali disiplinin korunması gereklidir. Sermaye hareketlerine yönelik esnek makro ihtiyati tedbirler ile rezerv yeterliliğinin güvence altına alınması da finansal sistemin dış şoklara karşı dayanıklılığını artıracaktır. Uzun vadede ise, ithalata dayalı üretim yapısının dönüşümünü ve cari açığın azaltılmasını hedefleyen sanayi ve teknoloji politikalarının yanı sıra, hukuk devleti ve kurumsal kaliteyi artıracak yapısal reformlar hayata geçirilmelidir. Bu tür bir reform ve politika bütünlüğü, erken uyarı sistemlerinden elde edilen sinyallerin etkin şekilde değerlendirilmesini sağlayarak ekonomik istikrarın güçlendirilmesine katkı sunacaktır.

Sonuç itibarıyla mevcut çalışma, Türkiye özelinde makroekonomik öncü göstergeler ile finansal krizlerin tetiklenmesi arasındaki ilişkilerin anlaşılmasına yönelik değerli bir adım teşkil etmektedir. Bununla birlikte, finansal krizlerin doğasında var olan ve öngörülemeyen küresel şoklar gibi dışsal faktörlerden kaynaklanan sistemik risklerin tamamen bertaraf edilmesinin mümkün olmadığı kabul edilmelidir. Ancak, bu tür çalışmalarla ortaya konan ampirik bulgular ışığında tasarlanacak etkin

politika müdahaleleri ve proaktif makro ihtiyati düzenlemeler aracılığıyla, finansal kriz risklerinin azaltılması ve potansiyel makroekonomik maliyetlerinin hafifletilmesi hedeflenmelidir.

Gelecek çalışmalar için, bu araştırmanın metodolojik çerçevesi çeşitli yönlerden genişletilebilir. Öncelikle, finansal krizlerin dinamik doğasını daha iyi yakalayabilmek adına Derin Öğrenme (Deep Learning) modelleri, özellikle Uzun Kısa Süreli Bellek (LSTM) ağları gibi zaman serisi verilerinde üstün performans sergileyen yapılar entegre edilebilir. Bu, karmaşık ve doğrusal olmayan ilişkilerin daha detaylı bir şekilde analiz edilmesini sağlayacaktır. Nicel yöntemlerin yanı sıra, kriz dönemlerine ilişkin nitel verilerin (örneğin, politika yapıcılarının söylemleri, piyasa beklentileri) metin madenciliği (text mining) teknikleriyle analizi, krizlerin oluşumuna dair daha derinlemesine bir anlayış sunabilir. Son olarak, model performansının gerçek zamanlı veri akışıyla sürekli güncellendiği adaptif erken uyarı sistemlerinin geliştirilmesi, politika yapıcılarının karar alma süreçlerinde daha proaktif olmalarını sağlayacak ve finansal istikrarın korunmasına yönelik çabalara önemli katkılar sunacaktır.

Kaynakça

- Aizenman, J., & Binici, M. (2016). Exchange market pressure in OECD and emerging economies: Domestic vs. external factors and capital flows in the old and new normal. *Journal of International Money and Finance*, 66, 65-87.
- Akçalı, B. Y. (2015). MIST Ülkeleri Finansal Baskı Endeksleri (FBE)nin Yapay Sinir Ağları ve Box-Jenkins Yöntemleriyle Tahmin Edilerek Finansal Krizlerin Öngörülmesi. *Muhasebe Bilim Dünyası Dergisi*, 17(2), 347-384.
- Alessi, L., & Detken, C. (2018). Identifying excessive credit growth and leverage. *Journal of financial stability*, 35, 215-225.
- Altıntaş, H., & Öz, B. (2007). Para Krizlerinin Sinyal Yaklaşımı ile Öngörülebilirliği: Türkiye Uygulaması. *Anadolu University Journal of Social Sciences/Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 7(2).
- Anderson, R. G., Bordo, M., & Duca, J. V. (2017). Money and velocity during financial crises: From the great depression to the great recession. *Journal of Economic Dynamics and Control*, 81, 32-49.
- Apostolakis, G. N., Giannellis, N., & Papadopoulos, A. P. (2019). Financial stress and asymmetric shocks transmission within the Eurozone. How fragile is the common monetary policy?. *The North American Journal of Economics and Finance*, 50, 101006.
- Avcı, M. A., & Altay, N. O. (2013). Finansal Krizlerin Sinyal Yaklaşımı ile Öngörülmesi: Türkiye, Arjantin, Tayland ve İngiltere için Bir Analiz. *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (14), 47-58.
- Avcı, M. A., & Altay, N. O. (2014). Finansal krizlerin öngörüsünde regresyon ağaçları modeli: Gelişmekte olan ülkelere yönelik bir analiz. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*.
- Aydin, A. D., & Cavdar, S. C. (2015). Prediction of financial crisis with artificial neural network: an empirical analysis on Turkey. *International journal of financial research*, 6(4), 36.
- Aydin, Ü. (2022). *Türkiye’de 1980 Sonrası dönemde yaşanan ekonomik krizlerin analizi*. İzmir Akademi Derneği.
- Bayram Arlı, N., Barca, O., & Görentaş, M. B. (2022). Rassal Orman. Bayram Arlı, N., Gürsakal, S. & Engin, M. (Der.), Denetimli Makine Öğrenmesi Algoritmaları (119-148). Ankara: Nobel Yayıncılık.
- Beutel, J., List, S., & von Schweinitz, G. (2019). Does machine learning help us predict banking crises?. *Journal of Financial Stability*, 45, 100693.
- Bluwstein, K., Buckmann, M., Joseph, A., Kapadia, S., & Şimşek, Ö. (2023). Credit growth, the yield curve and financial crisis prediction: Evidence from a machine learning approach. *Journal of International Economics*, 145, 103773.
- Breiman, L., Friedman, J. H., Olshen, R. A., ve Stone, C. J. (1984). Classification and Regression Trees. Wadsworth and Brooks, Monterey, CA.
- Calvo, G. A., & Reinhart, C. M. (2002). Fear of floating. *The Quarterly journal of economics*, 117(2), 379-408.
- Calvo, G. A., Leiderman, L., & Reinhart, C. M. (1996). Inflows of Capital to Developing Countries in the 1990s. *Journal of economic perspectives*, 10(2), 123-139.
- Casabianca, E. J., Catalano, M., Forni, L., Giarda, E., & Passeri, S. (2022). A machine learning approach to rank the determinants of banking crises over time and across countries. *Journal of International Money and Finance*, 129, 102739.
- Catao, L. A., & Terrones, M. E. (2005). Fiscal deficits and inflation. *Journal of Monetary Economics*, 52(3), 529-554.

- Chatzis, S. P., Siakoulis, V., Petropoulos, A., Stavroulakis, E., & Vlachogiannakis, N. (2018). Forecasting stock market crisis events using deep and statistical machine learning techniques. *Expert systems with applications*, 112, 353-371.
- Cutler, A., Cutler, D. R., & Stevens, J. R. (2012). Random forests. *Ensemble machine learning: Methods and applications*, 157-175.
- Çakmak, U. (2013). Finansal kırılganlık Endeksi (Türkiye 1989-2011) ve Yorumlar. *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 32(1), 239-260.
- Çeşmeci, Ö., & Önder, A. Ö. (2008). Determinants of currency crises in emerging markets: The case of Turkey. *Emerging Markets Finance and Trade*, 44(5), 54-67.
- Davis, E. P., & Karim, D. (2008). Could early warning systems have helped to predict the sub-prime crisis?. *National Institute Economic Review*, 206, 35-47.
- Demirgüç-Kunt, A., & Detragiache, E. (1998). *Financial liberalization and financial fragility* (No. 1917). World Bank Publications.
- Dornbusch, R. (2002). 16. A Primer on Emerging-Market Crises. In S. Edwards & J. Frankel (Ed.), *Preventing Currency Crises in Emerging Markets* (pp. 743-754). Chicago: University of Chicago Press. <https://doi.org/10.7208/9780226185057-018>
- Duttagupta, R., & Cashin, P. (2011). Anatomy of banking crises in developing and emerging market countries. *Journal of International Money and Finance*, 30(2), 354-376.
- Easterly, W., & Rebelo, S. (1993). Fiscal policy and economic growth. *Journal of monetary economics*, 32(3), 417-458.
- Edison, H. J. (2003). Do indicators of financial crises work? An evaluation of an early warning system. *International Journal of Finance & Economics*, 8(1), 11-53.
- Eichengreen, B., Rose, A. K., & Wyplosz, C. (1996). Contagious currency crises NBER Working Paper, No: 5681.
- Emin, D. (2017). Türkiye'nin finansal krizleri ve göstergeleri. *Finansal Araştırmalar ve Çalışmalar Dergisi*, 9(17), 115-128.
- Fischer, S., Sahay, R., & Végh, C. A. (2002). Modern hyper-and high inflations. *Journal of Economic literature*, 40(3), 837-880.
- Frankel, J. A., & Rose, A. K. (1996). Currency crashes in emerging markets: An empirical treatment. *Journal of international Economics*, 41(3-4), 351-366.
- Genuer, R., Poggi, J. M., & Tuleau-Malot, C. (2010). Variable selection using random forests. *Pattern recognition letters*, 31(14), 2225-2236.
- Giannellis, N., & Tzanaki, M. A. (2025). Macroeconomic responses to financial stress shocks: Evidence from the US and the Eurozone. *International Economics*, 181, 100573.
- Goldstein, M., & Turner, P. (1998). Banking crises in emerging economies: origins and policy options. *Available at SSRN* 52074.
- Greenwood, R., Hanson, S. G., Shleifer, A., & Sørensen, J. A. (2022). Predictable financial crises. *The Journal of Finance*, 77(2), 863-921.
- Holopainen, M., & Sarlin, P. (2017). Toward robust early-warning models: A horse race, ensembles and model uncertainty. *Quantitative Finance*, 17(12), 1933-1963.
- Huang, C., Simpson, S., Ulybina, D., & Roitman, A. (2019). *News-based sentiment indicators*. International Monetary Fund.

- Ishrakieh, L. M., Dagher, L., & El Hariri, S. (2019). Not the usual suspects: Critical indicators in a dollarized country's financial stress index. *Finance Research Letters*. <https://doi.org/10.1016/j.frl.2019.03.037>
- Jeanne, O., & Rancière, R. (2011). The optimal level of international reserves for emerging market countries: A new formula and some applications. *The Economic Journal*, 121(555), 905-930.
- Kaminsky, G. L., & Reinhart, C. M. (1999). The twin crises: the causes of banking and balance-of-payments problems. *American economic review*, 89(3), 473-500.
- Kaminsky, G., Lizondo, S., & Reinhart, C. (1998, March). Leading Indicators of Currency Crises, IMF Staff Papers, 45(1). <http://dx.doi.org/10.2307/3867328>
- Karabulut, G., Bilgin, M. H., & Danisoglu, A. C. (2010). Determinants of currency crises in Turkey: Some empirical evidence. *Emerging Markets Finance and Trade*, 46(sup1), 51-58.
- KAS, M. H., & ÇIRPICI, Y. A. (2024). Türkiye’de Finansal Krizlerin Öngörülebilirliği: YSA Tabanlı Erken Uyarı Sistemi. *Ekonomik Yaklaşım*, 35(130).
- Kaya, V., & Yilmaz, O. (2007). *Para krizleri öngörüsünde logit model ve sinyal yaklaşımının değeri: Türkiye tecrübesi* (No. 2007/1). Discussion Paper.
- Kindleberger, C. P. (2000). Manias, panics, and crashes: a history of financial crises. *The Scribnerian and the Kit-Cats*, 32(2), 379.
- Krugman, P. (1979). A model of balance-of-payments crises. *Journal of money, credit and banking*, 11(3), 311-325.
- Lane, P. R., & Milesi-Ferretti, G. M. (2007). The external wealth of nations mark II: Revised and extended estimates of foreign assets and liabilities, 1970–2004. *Journal of international Economics*, 73(2), 223-250.
- Lee, T. H., Ullah, A., & Wang, R. (2020). Bootstrap aggregating and random forest. *Macroeconomic forecasting in the era of big data: Theory and practice*, 389-429.
- Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R news*, 2(3), 18-22.
- Lin, C. S., Khan, H. A., Chang, R. Y., & Wang, Y. C. (2008). A new approach to modeling early warning systems for currency crises: Can a machine-learning fuzzy expert system predict the currency crises effectively?. *Journal of International Money and Finance*, 27(7), 1098-1121.
- Liu, L., Chen, C., & Wang, B. (2022). Predicting financial crises with machine learning methods. *Journal of Forecasting*, 41(5), 871-910.
- Longstaff, F. A., Pan, J., Pedersen, L. H., & Singleton, K. J. (2011). How sovereign is sovereign credit risk?. *American Economic Journal: Macroeconomics*, 3(2), 75-103.
- Milesi-Ferretti, G. M., & Razin, A. (1996). *Current-account sustainability*. International Finance Section, Princeton University.
- Mishkin, F. S. (1996). The channels of monetary transmission: Lessons for monetary policy.
- Obstfeld, M. (1995). The logic of currency crises. In *Monetary and fiscal policy in an integrated Europe* (pp. 62-90). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Obstfeld, M., & Rogoff, K. (1996). *Foundations of international macroeconomics*. MIT press.
- Ozcelebi, O. (2020). Assessing the impacts of financial stress index of developed countries on the exchange market pressure index of emerging countries. *International Review of Economics & Finance*, 70, 288-302.
- Ozcelebi, O., Perez-Montiel, J., & Manera, C. (2024). Bond yield spreads and exchange market pressure in emerging countries. *International Journal of Emerging Markets*.

- Pentecost, E. J., Van Hooydonk, C., & Van Poeck, A. (2001). Measuring and estimating exchange market pressure in the EU. *Journal of International Money and Finance*, 20(3), 401-418.
- Polat, O., & Ozkan, I. (2019). Transmission mechanisms of financial stress into economic activity in Turkey. *Journal of Policy Modeling*, 41(2), 395-415.
- Pontines, V., & Siregar, R. (2008). Fundamental pitfalls of exchange market pressure-based approaches to identification of currency crises. *International Review of Economics & Finance*, 17(3), 345-365.
- Reinhart, C. M., & Rogoff, K. S. (2011). From financial crash to debt crisis. *American economic review*, 101(5), 1676-1706.
- Rodrik, D. (2008). The real exchange rate and economic growth. *Brookings papers on economic activity*, 2008(2), 365-412.
- Santero, T., & Westerlund, N. (1996). *Confidence indicators and their relationship to changes in economic activity* (No. 170). OECD Publishing.
- Shankarpandala, S. (2024). *LazyPredict: A library for quick and easy model selection in machine learning*. Retrieved from [https://pypi.org/project/lazypredict/]
- Soe, T. T., & Kakinaka, M. (2018). Inflation targeting and exchange market pressure in developing economies: Some international evidence. *Finance Research Letters*, 24, 263-272.
- Söyler, H., & Kızılkaya, O. (2018). Para krizlerinin yapay zeka yöntemleri ile tahmini: Türkiye örneği. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 649-666.
- Stolbov, M., & Shchepeleva, M. (2016). Financial stress in emerging markets: Patterns, real effects, and cross-country spillovers. *Review of Development Finance*, 6(1), 71-81.
- Tölö, E. (2020). Predicting systemic financial crises with recurrent neural networks. *Journal of Financial Stability*, 49, 100746.
- Truong, C., Sheen, J., Trück, S., & Villafuerte, J. (2022). Early warning systems using dynamic factor models: An application to Asian economies. *Journal of Financial Stability*, 58, 100885.
- Tuzcuoglu, K. (2024). Nonlinear transmission of international financial stress. *Economic Modelling*, 139, 106805.
- Ural, M. & Balaylar, N.A. (2007). Bankacılık sektöründe yüksek risk alımı ve baskı indeksleri. *Finans Politik & Ekonomik Yorumlar*, 44, 509.
- Yildirim, I., Ozsahin, S., & Akyuz, K. C. (2011). Prediction of the financial return of the paper sector with artificial neural networks. *BioResources*, 6(4).

Extended Abstract

Background

The Turkish economy has experienced various financial crises in the past and considering the economic and social impacts of these crises, it is of great importance to develop effective crisis forecasting models specific to the country. The use of machine learning techniques that can analyze nonlinear structures and provide data-driven learning for financial crisis prediction has become important in financial crisis forecasting. This study aims to construct an EMPI for Turkey covering the period from January 2004 to December 2024 and integrate this index with a random forest algorithm to use it as an EWS for leading indicators of financial crises.

Research Purpose

This study aims to construct an Exchange Market Pressure Index (EMPI) for Turkey using a recent data set covering the period January 2004 - December 2024 and a large pool of leading indicators, and to predict financial crises by modelling this index with a random forest machine learning algorithm.

Methodology

In this study, crisis periods are first defined with the EMPI developed by Eichengreen et al. (1996). Subsequently, the crisis periods in Turkey are estimated with the random forest algorithm. The analysis of macroeconomic and financial indicators affecting crises is conducted through the utilisation of partial dependence plots, which facilitate a detailed examination of the relationship between variables.

Findings

The results show that the random forest algorithm is highly successful in crisis forecasting and supports a comprehensive decision-making process for policymakers by enabling the identification of the main economic determinants of financial crises. While emphasizing the potential of machine learning methods in financial crisis forecasting, this study also highlights the interpretability of the model and provides policy recommendations for financial stability.

Conclusion

The present study aims to identify macroeconomic and financial leading indicators that are effective in predicting crisis periods on the basis of EMPI. This is achieved by employing the random forest model. It is concluded that these indicators can be considered as early warning signals that signal potential crises. The leading indicators identified in the study are consistent with the theoretical framework proposed by Krugman (1979) with his first generation crisis models. In particular, the theoretical background that financing budget deficits through monetary expansion paves the way for crises by increasing inflationary pressure, balance of payments problems, capital flight and ultimately pressure on the exchange rate is supported by the indicators identified for Turkey. In this context, the considerable volatility in the real external value of the Turkish lira over the 2004-2024 period is consistent with theoretical predictions.