T.C.
DOKUZ EYLÜL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İKTİSAT ANABİLİM DALI
İKTİSAT PROGRAMI

DOKTORA TEZİ

FİNANSAL BALONLARIN VE KRİZLERİN MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE TAHMİNİ

Merve MERT SARITAŞ

Danışman
Prof. Dr. Mert URAL

2025

T.C.
DOKUZ EYLÜL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İKTİSAT ANABİLİM DALI
İKTİSAT PROGRAMI

DOKTORA TEZİ

FİNANSAL BALONLARIN VE KRİZLERİN MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE TAHMİNİ

Merve MERT SARITAŞ

Danışman
Prof. Dr. Mert URAL

İZMİR - 2025

DOKTORA
TEZ ONAY SAYFASI

Üniversite	: Dokuz Eylül Üniversitesi
Enstitü	: Sosyal Bilimler Enstitüsü
Adı ve Soyadı	: MERVE MERT SARITAŞ
Öğrenci No	: 2020801257
Tez Başlığı	: Finansal Balonların Ve Krizlerin Makine Öğrenmesi Yöntemleriyle Tahmini
Savunma Tarihi	: 21/07/2025
Danışmanı	: Prof.Dr. Mert URAL

JÜRİ ÜYELERİ

Ünvanı, Adı, Soyadı	Üniversitesi	İmza
Prof.Dr. Mert URAL	-Dokuz Eylül Üniversitesi	.....
Prof.Dr. Üzeyir AYDIN	-Dokuz Eylül Üniversitesi	.....
Prof. Dr. Erhan DEMİRELİ	-Dokuz Eylül Üniversitesi	.....
Prof. Dr. C. Coşkun KÜÇÜKÖZMEN	-İzmir Ekonomi Üniversitesi	.....
Doç.Dr. Ramazan EKİNCİ	-Bakırçay Üniversitesi	.....

MERVE MERT SARITAŞ tarafından hazırlanmış ve sunulmuş olan bu tez savunmada başarılı bulunarak oy birliği( ) / oy çokluğu( ) ile kabul edilmiştir.

Prof. Dr. Erhan DEMİRELİ
Müdür

YEMİN METNİ

Doktora tezi olarak sunduğum, “Finansal Balonların ve Krizlerin Makine Öğrenmesi Yöntemleriyle Tahmini” adlı çalışmanın, tarafımdan, akademik kurallara ve etik değerlere uygun olarak yazıldığını ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve bunu onurumla doğrularım.

21.7.2025

Merve MERT SARITAŞ

ÖZET

Doktora Tezi

Finansal Balonların ve Krizlerin Makine Öğrenmesi Yöntemleriyle Tahmini

Merve MERT SARITAŞ

Dokuz Eylül Üniversitesi

Sosyal Bilimler Enstitüsü

İktisat Anabilim Dalı

İktisat Programı

Bu çalışma, finansal istikrar açısından kritik öneme sahip olan finansal balonların ve krizlerin makine öğrenmesi yöntemleri kullanılarak tespitini ve tahminini araştırmaktadır. Çalışmanın temel amacı, finansal balonların ve krizlerin makroekonomik ve finansal göstergelerle ilişkilerini inceleyerek bu olguların erken tespiti için etkinliği yüksek erken uyarı sistemleri geliştirmek ve bu sistemlerin performansını değerlendirmektir. Bu kapsamda tez, spesifik araştırma sorularına odaklanan ve kendi içlerinde bütünlük arz eden üç ayrı makaleden oluşmaktadır. Tüm makalelerde nicel analiz yöntemleri ve çeşitli makine öğrenmesi algoritmaları kullanılmış; veri analizleri, Python, RStudio ve Eviews programları aracılığıyla gerçekleştirilmiştir.

İlk makalede, Türkiye'deki finansal balonlar GSADF testi aracılığıyla tespit edilmekte ve sonrasında bu balonların oluşumu, çeşitli makroekonomik göstergeler kullanarak rassal orman algoritması yardımıyla tahmin edilmektedir. Çalışma, temel belirleyicileri ortaya koyarak makine öğreniminin erken tespit potansiyelini göstermektedir. İkinci makalede, Türkiye'de finansal krizler temel alınarak rassal orman algoritmasıyla yüksek performanslı bir erken uyarı sistemi geliştirilmiştir. Bu yaklaşım, temel belirleyicileri tanımlayıp politika yapımını desteklemektedir. Üçüncü makalede ise G7 ülkelerindeki sistemik bankacılık krizleri XGBoost modeli ile tahminlenmekte ve SHAP değerleri kullanılarak model yorumlanabilirliği ve

şeffaflığı artırılmaktadır. Bulgular, uygulanan metodolojinin yüksek tahmin gücünü ve yaklaşımın kriz dinamiklerini anlamadaki önemini göstermiştir.

Sonuç olarak bu tez, Türkiye ve uluslararası düzeyde, finansal balonların ve krizlerin makine öğrenmesi yöntemleriyle başarıyla modellenebileceğini ve öngörülebileceğini göstermektedir. Geliştirilen modeller ve erken uyarı sistemleri, finansal istikrarın korunması ve piyasa risklerinin yönetimi açısından önemli katkılar sağlamakta, politika yapıcıların proaktif ve bilgiye dayalı kararlar almasına yardımcı olmaktadır. Aynı zamanda makine öğrenmesi modellerinin tahmin gücü kadar yorumlanabilirliğinin de finansal analizlerdeki önemini vurgulamaktadır.

Anahtar Kelimeler: Finansal Baloncuklar, Finansal Krizler, Tahminleme, Erken Uyarı, Makine Öğrenimi, Rassal Orman, XGBoost.

ABSTRACT

Doctoral Thesis

Doctor of Philosophy (PhD)

Forecasting Financial Bubbles and Crises Using Machine Learning Methods

Merve MERT SARITAŞ

Dokuz Eylül University

Graduate School of Social Sciences

Department of Economics

Economics Program

This study investigates the detection and forecasting of financial bubbles and crises, which are critical for financial stability, using machine learning methods. The principal objective of this dissertation is to develop robust and effective early warning systems capable of providing timely detection of financial bubbles and crises by analyzing their interrelationships with a comprehensive set of macroeconomic and financial indicators, and to rigorously evaluate the performance of these developed systems. To achieve this objective, the thesis comprises three distinct yet interconnected research articles, each addressing specific research questions. Quantitative analytical methods and a diverse array of machine learning algorithms are employed throughout all articles, with data analyses conducted utilizing Python, RStudio, and Eviews software packages.

The first paper of this dissertation focuses on the identification of financial bubbles in Türkiye through the application of the Generalized Supremum Augmented Dickey-Fuller (GSADF) test. Subsequently, the formation of these identified bubbles is predicted using a random forest algorithm incorporating various macroeconomic indicators. This study effectively demonstrates the early detection potential of machine learning techniques by elucidating the key determinants of financial bubble formation. The second paper details the development of a high-performance early warning system for financial crises in

Türkiye, employing a random forest algorithm grounded in relevant macroeconomic and financial data. This analytical approach not only identifies key determinants of financial crises but also provides valuable insights to support informed policymaking. The third paper shifts its focus to the prediction of systemic banking crises within the G7 economies, utilizing the XGBoost model. Furthermore, to enhance the interpretability and transparency of this model, SHAP (SHapley Additive exPlanations) values are employed. The findings of this analysis underscore the high predictive power of the applied methodology and highlight the importance of this approach in gaining a deeper understanding of systemic banking crisis dynamics.

In conclusion, this thesis provides compelling evidence that financial bubbles and crises, both within Türkiye and across international contexts, can be successfully modeled and predicted through the application of machine learning methods. The developed models and early warning systems represent significant contributions to the ongoing efforts aimed at maintaining financial stability and effectively managing market risks, thereby assisting policymakers in making proactive and evidence-based decisions. Moreover, this research emphasizes the dual importance of both the predictive power and the interpretability of machine learning models in the field of financial analysis.

Keywords: Financial Bubbles, Financial Crises, Forecasting, Early Warning, Machine Learning, Random Forest, XGBoost

FİNANSAL BALONLARIN VE KRİZLERİN MAKİNE ÖĞRENMESİ YÖNTEMLERİYLE TAHMİNİ

İÇİNDEKİLER

TEZ ONAY SAYFASI ii
YEMİN METNİ iii
ÖZET iv
ABSTRACT vi
İÇİNDEKİLER viii
KISALTMALAR xi
TABLOLAR LİSTESİ xiii
ŞEKİLLER LİSTESİ xiv

GİRİŞ 1

BİRİNCİ BÖLÜM
SAĞ KUYRUKLU ADF VE MAKİNE ÖĞRENMESİ YÖNTEMLERİNE DAYALI OLARAK FİNANSAL BALONCUKLARIN TESPİTİ VE TAHMİNLENMESİ

1.1. LİTERATÜR ARAŞTIRMASI 7
1.2. YÖNTEM 12
1.2.1. GSADF Testi 12
1.2.2. Rassal Orman 14
1.3. UYGULAMA 16
1.3.1. Balonların Tespiti 16
1.3.2. Rassal Orman Sonuçları 20
1.3.3. Rassal Orman Performans Ölçütleri (Başarısı) 21
1.3.4. Kısmi Bağımlılık Grafiği 30
1.4. SONUÇ 34

İKİNCİ BÖLÜM

RASSAL ORMAN ALGORİTMASINA DAYALI OLARAK TÜRKİYE'DE FİNANSAL KRİZLERİN TAHMİNLENMESİ

2.1. LİTERATÜR TARAMASI 39
2.2. VERİ SETİ 44
2.3. YÖNTEM 46
2.3.1. Finansal Baskı Endeksi 46
2.3.2. Rassal Orman 49
2.4. ANALİZ VE BULGULAR 50
2.4.1. LazyPredict ile Model Değerlendirme 51
2.4.2. Rassal Orman Uygulama Sonuçları 52
2.4.3. Kısmi Bağımlılık Grafikleri 60
2.5. SONUÇ 64

ÜÇÜNCÜ BÖLÜM

BİR MAKİNE ÖĞRENİMİ UYGULAMASI: G7 ÜLKELERİNDE FİNANSAL KRİZ TAHMİNLEME

3.1. LİTERATÜR TARAMASI 70
3.2. METODOLOJİ 73
3.2.1. Aşırı Gradyan Artırma (Extreme Gradient Boosting – XGBOOST) 73
3.2.2. SHAP Analizi 74
3.3. UYGULAMA 75
3.3.1. Veriler 75
3.3.2. Model Değerlendirme 77
3.3.3. Model Tanımı ve XGBoost Sonuçları 78
3.4. AMPİRİK BULGULAR 80
3.4.1. XGBoost Performans Sonuçları 80
3.4.2. Değişkenlerin Önem Düzeyleri 83

3.4.3. SHAP Değerleri 87
3.5. SONUÇ 94

SONUÇ VE ÖNERİLER 96
KAYNAKÇA 102

KISALTMALAR

ABD	Amerika Birleşik Devletleri
ADF	Augmented Dickey-Fuller
AUC	Eğri Altında Kalan Alan
BİST	Borsa İstanbul
BOGE	Bileşik Öncü Göstergeler Endeksi
BRICS	Brezilya, Rusya, Hindistan, Çin, Güney Afrika
BSADF	Backwards Sup ADF
CART	Sınıflandırma ve Regresyon Ağaçları
CDS	Kredi Temerrüt Takası
DVM	Destek Vektör Makinesi
EMPI	Finansal Baskı Endeksi
EVDS	Elektronik Veri Dağıtım Sistemi
EWS	Erken Uyarı Sistemleri
FBE	Finansal Baskı Endeksi
FED	ABD Merkez Bankası
FSE	Finansal Stres Endeksi
G7	Group of Seven
GPRC	Jeopolitik Risk Endeksi
GRU	Kapalı Geri Beslemeli Ünite
GSADF	Genelleştirilmiş Supremum Artırılmış Dickey-Fuller
GSMH	Gayrisafi Milli Hasıla
GSYİH	Gayrisafi Yurtiçi Hasıla
HMB	Hazine ve Maliye Bakanlığı
IFS	Uluslararası Finansal İstatistikler
LSTM	Uzun Kısa Süreli Bellek
MIST	Meksika, Endonezya, Güney Kore, Türkiye
MLP	Çok Katmanlı Algılayıcı
NPV	Negatif Tahmin Değeri

OECD	Ekonomik Kalkınma ve İşbirliği Örgütü
PDP	Kısmi Bağımlılık Grafiği
PPV	Pozitif Tahmin Değeri
PSY	Phillips–Shi–Yu Sağ Kuyruklu Birim Kök Testi
ROC	Alıcı İşlem Karakteristik Eğrisi
RTADF	Sağ Kuyruklu Augmented Dickey-Fuller
SADF	Supremum Augmented Dickey Fuller
SHAP	Shapley Additive Explanations
SMOTE	Sentetik Azınlık Artırma Tekniği
TCMB	Türkiye Cumhuriyet Merkez Bankası
TÜFE	Tüketici Fiyat Endeksi
TÜİK	Türkiye İstatistik Kurumu
ÜFE	Üretici Fiyatları Endeksi
VAR	Vektör Otoregresyon
XAI	Açıklanabilir Yapay Zekâ
XBANK	Borsa İstanbul Banka Endeksi
XGBoost	Ekstra Gradyan Artırma
XU100	Borsa İstanbul 100 Endeksi
XUSIN	Borsa İstanbul Sanayi Endeksi
YSA	Yapay Sinir Ağları

TABLOLAR LİSTESİ

Tablo 1: Dışsal Değişkenlerin Kategorileri s. 17
Tablo 2: GSADF Test İstatistikleri ve Kritik Değerler s. 18
Tablo 3: Balon Dönemleri s. 19
Tablo 4: Tahmine Dayalı Performans Ölçütleri s. 22
Tablo 5: BIST Endeksleri Erken Uyarısı İçin Karışıklık Matrisi s. 22
Tablo 6: Değişkenlerin Önem Düzeyleri s. 27
Tablo 7: Finansal Kriz Tahminlemesinde Kullanılan Değişkenler ve Açıklamaları s. 45
Tablo 8: FBE ile Belirlenen Kriz Dönemleri s. 48
Tablo 9: LazyPredict Rassal Orman Tahmin Sonuçları s. 52
Tablo 10: Model İyileştirme Sonrası En İyi Parametreler s. 53
Tablo 11: Rassal Orman Modeli Tahmin Performans Sonuçları s. 54
Tablo 12: Potansiyel Kriz Tahmincileri Önem Oranları s. 57
Tablo 13: Kriz Tahminlemesinde Kullanılan Değişkenler ve Açıklamaları s. 76
Tablo 14: G7 Ülkeleri için LazyPredict XGBoostClassifier Tahmin Sonuçları s. 77
Tablo 15: Hiperparametre Aralıkları s. 79
Tablo 16: Model iyileştirme sonrası en iyi parametreler s. 79
Tablo 17: XGBoost Sınıflandırıcının Tahmin Performans Sonuçları s. 80
Tablo 18: G7 Ülkelerine ait Değişken Önem Düzeyleri s. 85

ŞEKİLLER LİSTESİ

Şekil 1: Rassal Orman (Random Forest) Sınıflandırıcısı s. 15
Şekil 2: Endeksler için GSADF Test Sonuçları ve Balon Dönemlerinin Toplu Gösterimi s. 18
Şekil 3: Balon Varlığını Tahminleyen Karışıklık Matrisi Sonuçları s. 23
Şekil 4: Rassal Orman Sınıflandırıcısının ROC Eğrileri s. 26
Şekil 5: Balon Tahminlemede Makroekonomik ve Finansal Faktörlerin Önem Oranları s. 28
Şekil 6: XU100 için Kısmi Bağımlılık Grafikleri s. 32
Şekil 7: XBANK için Kısmi Bağımlılık Grafikleri s. 32
Şekil 8: XUSIN için Kısmi Bağımlılık Grafikleri s. 33
Şekil 9: Türkiye'de Kriz Dönemleri s. 39
Şekil 10: 2004-2024 Dönemi için FBE ile Belirlenen Finansal Krizler s. 47
Şekil 11: Öncü Göstergeler Arasındaki Korelasyon Değerleri s. 51
Şekil 12: Kriz Tahminlemesinde ROC eğrisi ve Karmaşıklık Matrisi s. 55
Şekil 13: Potansiyel Kriz Tahmincileri Önem Oranları Bar Grafiği s. 56
Şekil 14: Öncü Göstergeler Kısmi Bağımlılık Grafikleri s. 62
Şekil 15: G7 Ülkelerinde Yaşanan Finansal Kriz Yoğunluğu s. 69
Şekil 16: Yöntem Akışı s. 69
Şekil 17: Japonya için LazyClassifier Tahmin Sonuçları s. 78
Şekil 18: G7 Ülkeleri için XGBoost ROC Eğrisi ve AUC Değerleri s. 83
Şekil 19: G7 Ülkeleri için Potansiyel Kriz Tahmincileri s. 84
Şekil 20: SHAP Analizi Sonuçları s. 89
Şekil 21: SHAP Force Plot Sonuçları s. 91

GİRİŞ

Finansal balonlar ve finansal krizler, karmaşık bir etkileşim içinde bulunan ve birbirini tetikleyen iktisadi olgulardır. Finansal balonlar, genellikle finansal krizlerin habercisi veya doğrudan tetikleyicisi olarak kabul edilmekte ve aşırı iyimserlik ile spekülasyonun etkisiyle oluşan fiyat artışları, varlık değerlerinin reel ekonomik değerlerden uzaklaşmasına yol açmaktadır (Kindleberger, 2000; Shiller, 2000). Bu durum, ekonomik temellerden kopuk bir büyüme illüzyonu yaratarak sistemin şoklara karşı direncini azalmtaktadır. Balonların patlaması ise varlık fiyatlarında hızlı bir düşüşe yol açarak yatırımcıların panik satışlarına ve piyasada likidite sorunlarına neden olma yoluyla finansal krizleri tetiklemektedir (Minsky, 1986; Reinhart ve Rogoff, 2011). Varlık fiyatlarındaki hızlı düşüşler, finansal kuruluşların bilançolarını olumsuz etkilemekte, kredi kanallarını tıkayarak ekonomik aktiviteyi sekteye uğratmaktadır. Finansal krizler, uzun süren balon dönemlerinin ardından ortaya çıkarak biriken dengesizlikleri düzeltici bir mekanizma işlevi görmekle birlikte, bu süreç genellikle ekonomik aktivite üzerinde maliyetli ve uzun süreli olumsuz etkilere yol açmaktadır (Allen ve Gale, 2009; Brunnermeier, 2009). Bu nedenle finansal balonların etkin bir şekilde yönetilmesi, krizlerin önlenmesi ve finansal istikrarın sağlanması açısından büyük önem arz etmektedir.

Finansal piyasalarda gözlemlenen pozitif ve negatif yönlü balonların tespiti, potansiyel finansal krizler için önemli bir erken uyarı mekanizması olarak değerlendirilmektedir. Pozitif finansal balonlar, varlık fiyatlarının ekonomik temellerden ayrılarak aşırı değerlenmesini ifade eder ve piyasadaki irrasyonel davranışları, spekülasyonu ve aşırı iyimserliği yansıtarak finansal sistemde dengesizlikler yaratarak ani bir düzeltme riskini artırmaktadır. Bu nedenle, pozitif balonların erken tespiti, makro ihtiyati araçlar aracılığıyla balonun büyümesini engellemek veya etkilerini hafifletmek amacıyla politika yapıcılar için kritik bir erken uyarı sinyali sunmaktadır. Negatif finansal balonlar ise, varlık fiyatlarının ekonomik temellerle açıklanamayacak şekilde aşırı düşüş göstermesi durumunu ifade etmekte ve piyasalarda aşırı kötümserliği, panik satışlarını ve likidite sorunlarını işaret etmektedir. Bu tür balonlar, genellikle finansal krizlerin bir

sonucu veya tetikleyicisi olarak ortaya çıkmakta ve bankacılık sektöründeki sorunlar veya ekonomik durgunluk gibi derin sorunların habercisi olabilmektedir. Negatif balonların tespiti, para ve maliye politikası araçları ile piyasaların istikrara kavuşturulması ve ekonomik aktivitenin desteklenmesi amacıyla kullanılabilmektedir. Hem pozitif hem de negatif balonların birlikte değerlendirilmesi, finansal sistemin genel sağlığı hakkında daha kapsamlı bir risk değerlendirmesi imkânı sunarak finansal istikrarın sağlanması ve ekonomik krizlerin önlenmesi açısından kritik bir rol oynamaktadır.

Bu çalışma, finansal balonların ve krizlerin makroekonomik ve finansal göstergelerle ilişkilerini analiz ederek bu olguların erken tespiti için yüksek performanslı erken uyarı sistemleri geliştirilmesine ve bu sistemlerin etkinliğinin değerlendirilmesine odaklanmaktadır. Bu amaç doğrultusunda tez, finansal balonların ve krizlerin öncü göstergeler kullanılarak makine öğrenmesi yöntemleriyle tahminlenmesini ele alan üç özgün makaleden oluşmaktadır. Araştırma, ilk olarak Türkiye özelinde balon ve kriz dinamiklerini incelemekte, ardından kapsamı G7 ülkelerini içerecek şekilde genişletmektedir.

Tezin ilk makalesi olan "Sağ Kuyruklu ADF ve Makine Öğrenmesi Yöntemlerine Dayalı Olarak Finansal Baloncukların Tespiti ve Tahminlenmesi", Türkiye'de BİST endekslerinde gözlemlenen finansal balonları Genelleştirilmiş Supremum Artırılmış Dickey-Fuller (GSADF) testiyle tespit etmekte ve rassal orman (random forest) algoritması kullanarak makroekonomik göstergeler temelinde tahminlemektedir. Bu çalışma, önerilen yaklaşımın balonları öngörmede yüksek tahmin gücüne sahip etkili bir alternatif olduğunu ortaya koymaktadır.

İkinci makale, "Rassal Orman Algoritmasına Dayalı Olarak Türkiye'de Finansal Krizlerin Tahminlenmesi" başlığı altında, 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. Finansal Baskı Endeksi (FBE) ile tanımlanan kriz dönemleri ve Türkiye ekonomisine ait temel makroekonomik ve finansal göstergeler kullanılarak rassal orman algoritmasının tahmin performansı değerlendirilmiş;

algoritmanın kriz tahmininde yüksek başarı sergilediği ve politika yapıcılara temel ekonomik belirleyiciler konusunda değerli bilgiler sunduğu gösterilmiştir.

"Bir Makine Öğrenimi Uygulaması: G7 Ülkelerinde Finansal Kriz Tahminleme" başlıklı üçüncü makale ise, araştırmayı G7 ülkelerine genişleterek uzun bir tarihsel perspektifte sistemik bankacılık krizlerini XGBoost (Ekstra Gradyan Artırma) modeli ile tahminlemektedir. Bu çalışmada ayrıca, modelin karar alma süreçlerini anlamlandırmak amacıyla SHAP (SHapley Additive exPlanations) yöntemleri uygulanarak model sonuçları arasındaki nedensel ilişkiler analiz edilmiştir. Bulgular, XGBoost modelinin yüksek tahmin performansının yanı sıra, SHAP değerlerinin model şeffaflığını ve hesap verebilirliğini artırarak kriz dinamiklerinin anlaşılmasına ve politika değerlendirmelerine önemli katkılar sağladığını vurgulamaktadır.

Bu makalelerde kullanılan makine öğrenmesi yöntemleri (Rassal orman, XGBoost), karmaşık ve doğrusal olmayan ilişkileri modelleyebilme, büyük veri setlerinde hesaplama verimliliği sağlama ve model karmaşıklığını kontrol altında tutarak genelleme performansını artırma gibi avantajları nedeniyle tercih edilmiştir. Özellikle XGBoost gibi modellerin yorumlanmasındaki zorlukları aşmak ve model kararlarını şeffaflaştırmak amacıyla SHAP gibi açıklanabilirlik yöntemlerine başvurulmuştur.

Literatürdeki çalışmalarda finansal krizlerin erken tespiti için çoğunlukla geleneksel istatistiksel yöntemlerini kullanılırken makine öğrenmesi yöntemlerinin kullanımı ise sınırlı kalmaktadır. Bu tezde yer alan çalışmaların, finansal balonlar ve krizlerin belirlenmesi ile öngörülmesine yönelik analizlerde makine öğrenmesi yöntemlerinin metodolojik avantajlarından faydalanarak literatüre önemli katkılar sunması beklenmektedir. Çalışmanın metodolojik katkıları arasında; dengesiz veri kümeleri için uygun önişleme yöntemlerinin kullanılması, makine öğrenimi modellerinin geçerliliğinin titiz doğrulama süreçleriyle test edilmesi ve finansal krizlere yol açan ulusal ve uluslararası etkenlerin Türkiye ile G7 ülkeleri bağlamında detaylı olarak incelenmesi yer almaktadır. Bu metodolojik ve analitik derinlik sayesinde, finansal krizlerin erken tespiti amacıyla hem Türkiye hem de uluslararası düzeyde sağlam, şeffaf ve uygulanabilir modelleme yaklaşımları geliştirilmesi hedeflenmektedir.

Tez finansal balonlar ve krizler üzerine gerçekleştirilen üç bağımsız ancak tematik olarak bağlantılı araştırma makalesinin sunulduğu ilk üç bölüm ile bu makalelerdeki bulguların bütüncül bir değerlendirmesinin yapıldığı son bölümden oluşmaktadır. Birinci, ikinci ve üçüncü bölümlerde yer alan makalelerde yürütülen ampirik analizler neticesinde ulaşılan sonuçlar, tezin "Sonuçlar ve Öneriler" olarak adlandırılan kapanış bölümünde sentezlenmiştir. Bu nihai bölümde, araştırma boyunca elde edilen temel bulgular özetlenmekte ve bu bulgulardan hareketle geliştirilen, finansal istikrar politikalarına ışık tutabilecek nitelikteki önerilere yer verilmektedir.

BİRİNCİ BÖLÜM
SAĞ KUYRUKLU ADF VE MAKİNE ÖĞRENMESİ YÖNTEMLERİNE DAYALI OLARAK FİNANSAL BALONCUKLARIN TESPİTİ VE TAHMİNLENMESİ

Balon kelime anlamı olarak rasyonellikten uzak sürü davranışı içeren pozitif veya negatif yönlü patlayıcı davranışlar olarak tanımlanabilir. Finansal piyasalardaki balon ise, bir ekonomik varlığın piyasa değerinin temel değerinden sürekli ve sistematik bir biçimde sapması durumudur (Santoni, 1987). Brunnermeier'e (2016) göre balonlar, bir varlığın fiyatının temel değerinden daha yüksek olması durumunda ortaya çıkmaktadır. Temel değerin belirleyicileri arasında tahmini getiriler, varlığın tahmini nihai değeri ve iskonto oranı yer almaktadır. Dolayısıyla, bir varlığın cari fiyatı yüksek olduğunda ve temel faktörler bu fiyatı desteklemediğinde, bir balonun var olduğu söylenmektedir (Stiglitz, 1990).

Literatürde, bir finansal balon, varlık fiyatının içsel değerini aştığı durum olarak tanımlanmakta olup erken uyarı sinyalleri olarak değerlendirilmeleri, politika yapıcılar ve düzenleyiciler için kritik öneme sahiptir. Finansal balonların öngörülmesi, uygulamalı finans literatüründe önemli bir araştırma konusu olarak kabul görmektedir. Varlık fiyatlarının temel değerini aşması durumunda ortaya çıkan balonlar, finansal sistemde rolü olan politika yapıcılar ve finansal düzenleyiciler için önemli riskler oluşturmaktadır (Case ve Shiller, 2003). Bu nedenle borsa verilerindeki anormalliklerin tespiti, finansal krizlerin başlangıcını belirlemek ve varlık fiyat balonlarını izlemek için önemli bir rol oynamaktadır. Bir varlık fiyat balonu, genellikle varlık fiyatlarının temel değerini aşması durumu olarak tanımlanır ve balonlar, piyasa fiyatları ile gerçek değerler arasındaki anormal fark olarak da düşünülebilir. Bu nedenle, erken uyarı sinyallerinden biri olarak balonların öngörülmesi, gelecekteki krizlere karşı önleyici tedbirler almakla sorumlu olan politika yapıcılar ve düzenleyiciler için hayati önem taşımaktadır. Bu nedenle, balon oluşumundaki ana faktörleri anlamak ve bunları erken aşamalarında tahmin etmek için artan sayıda çalışma yapılmaktadır.

Fiyatlarda meydana gelen balon dönemleri Phillips, Shi ve Yu (2015) çalışmasında geliştirilen özyinelemeli bir sağ kuyruklu genelleştirilmiş supremum artırılmış dickey

fuller testi (GSADF) tahminlenerek belirlenmektedir. Çalışmada kullanılan bir diğer yöntem olan makine öğrenmesi ise bilgisayarlara açıkça programlanmadan öğrenme yeteneği vermektedir. Makine öğrenmesi yöntemlerinden olan rassal orman algoritması ise büyük veri setlerindeki karmaşık örüntüleri tespit edebilme ve genelleme yeteneği sayesinde finansal balonların tahmininde güçlü bir yöntem olarak karşımıza çıkmaktadır.

Bu çalışmanın amacı, 2002-2024 dönemi boyunca BİST 100, BİST Banka ve BİST Sınai endeksindeki finansal balonları ekonometrik ve makine öğrenimi yöntemlerini birleştirerek tespit etmek ve öngörmektir. Çalışmanın ilk aşamasında, söz konusu BİST endekslerindeki balonların tespiti amacıyla sağ kuyruklu birim kök testleri kullanılmıştır. Zaman serilerindeki yapısal kırılmaları ve oynaklık değişimlerini dikkate alma yetenekleri sayesinde bu testler, balonların varlığını saptamada oldukça etkin bir metodoloji sunmaktadır (Shi vd., 2011). Balonların varlığını doğrulamada temel bir aşama teşkil eden söz konusu testler, fiyat serilerinde patlayıcı bir davranışın varlığına işaret ederek bir balonun varlığına dair ampirik kanıt sağlamaktadır.

Borsa endekslerinin, makroekonomik göstergeler, sosyo-politik değişimler, yatırımcı tercihleri, çeşitli beklenti ve güven endeksleri gibi çok sayıda farklı faktörden etkilenmesi, endeks tahminlemesini oldukça güçleştirmektedir (Liu vd., 2012). Günümüzde tahminleme modellerinde makine öğrenme algoritmaları oldukça sık kullanılmakta ve gayet başarılı sonuçlar elde edilmektedir. Buna istinaden çalışmanın ikinci aşamasında ise, balon oluşumunu makroekonomik göstergelerle ilişkilendirerek tahmin etmek için rassal orman (random forest) algoritması kullanılmıştır. Tahminleme modeli için hedef değişkeni etkileyen parametrelerden bir öznitelik kümesi oluşturulmuş ve makine öğrenme algoritmaları ile hedef veri tahmin edilmeye çalışılmıştır. BIST 100, BIST Banka ve BIST Sınai endeksinin hem makroekonomik hem de finansal göstergelerden etkilendiği düşünülerek bu göstergelerden oluşan bir öznitelik kümesi oluşturulmuş, makine öğrenmesi algoritmaları ile hedef değişken olan endekslerdeki balonlar tahmin edilmeye çalışılmıştır.

Çalışmanın ikinci bölümünde kapsamlı bir literatür taraması gerçekleştirilmiş ve çalışmada kullanılacak olan makine öğrenmesi tabanlı balon tahmini yönteminin literatürdeki yeri ile özgün katkıları ortaya konulmuştur. Üçüncü bölümde, GSADF testi

ve rassal orman algoritmasına ilişkin kuramsal çerçeve sunulmuş; yönteme dair temel kavramlara açıklık getirilmiştir. Dördüncü bölümde ise seçilen endeksler üzerinde GSADF testi ve rassal orman yöntemi kullanılarak elde edilen ampirik bulgular ayrıntılı biçimde değerlendirilmiş ve modelin tahmin performansı çeşitli ölçütler çerçevesinde analiz edilmiştir. Beşinci ve son bölümde, çalışmanın genel değerlendirmesine ve ulaşılan sonuçlara yer verilmiş; aynı zamanda araştırmanın kapsamını ve temel araştırma sorularını bütüncül bir bakış açısıyla ele alan çıkarımlar sunulmuştur. Finansal balonların tespiti ve analizinin, finansal istikrarın sağlanması bakımından kritik bir rol üstlendiği dikkate alındığında, bu tez kapsamında Borsa İstanbul hisse senedi piyasasında balon oluşumlarını öngörmeye yönelik olarak gerçek zamanlı balon tespit testi ile rassal orman algoritmasına dayanan iki aşamalı bir makine öğrenmesi yöntemi önerilmektedir.

Bu çalışmanın literatüre katkısı, borsa endeks fiyatlarında meydana gelen balonları tespit ederek balon oluşumlarına neden olan makroekonomik faktörlerin ilişkisini açıklamak ve bu ilişkiler çerçevesinde balon dönemlerinin makine öğrenimi yöntemleriyle öngörülebilirliğini sağlamasıdır. Bu doğrultuda, makroekonomik değişkenlerin dinamik etkileşimleri analiz edilerek piyasa davranışlarının daha derinlemesine anlaşılması amaçlanmaktadır.

1.1. LİTERATÜR ARAŞTIRMASI

Borsa verilerindeki anormalliklerin tespit edilmesi, finansal krizlerin genellikle varlık fiyatlarındaki bir patlama ve çöküş döngüsünü, yani varlık fiyat balonlarını takip etmesi nedeniyle çok önemli hale gelmiştir. Balon genellikle varlık fiyatlarının temel değerini aştığı bir durum olarak tanımlanır. Gilles ve Leroy (1992) balonları piyasa fiyatları ile gerçek değerler arasındaki anormal fark olarak tanımlamıştır. Teorik bir bakış açısıyla, herhangi bir varlığın gerçek veya temel değeri, gelecekteki tüm nakit akışlarının gerekli getiri oranıyla iskonto edilmiş bugünkü değerlerinin toplamına eşittir. Tarih, balonların öngörülmesinin, finansal sistemin refahından sorumlu olan politika yapıcılar ve finansal düzenleyiciler için her zaman hayati önem taşıdığını göstermektedir. Bundan

sonra, literatürde giderek artan sayıda çalışma, krizlere yol açan anormal borsa davranışlarını tespit etmek için erken uyarı sistemleri geliştirmeye çalışmıştır.

Literatürde Borsa İstanbul endeks fiyatlarını etkileyen faktörlerin belirlenmesi ve tahmin edilmesi amacıyla yapılan pek çok çalışma bulunmakla beraber, söz konusu çalışmalarda farklı teknikler kullanılmıştır. Chang vd. (2014), 1990-2003 döneminde BRICS ülkelerinde çoklu finansal balon oluşumlarının varlığını SADF ve GSADF testlerini kullanarak kapsamlı bir şekilde incelemişlerdir. Bu çalışma, gelişmekte olan piyasalarda finansal balonların yaygınlığına dair önemli bir kanıt sunmaktadır. Phillips vd. (2015a), 1871'den 2010'a kadar S&P 500 endeksine hem SADF hem de GSADF testlerini uygulamışlar ve 1873 Paniği (Ekim 1879'dan Nisan 1880'e kadar) ve dot-com balonu (Temmuz 1997'den Ağustos 2001'e kadar) olmak üzere GSADF'nin iki balon dönemini başarıyla tespit ettiğini ortaya koymuşlardır. Popüler bir gerçek zamanlı balon tespit testi olan GSADF Phillips, Shi ve Yu tarafından 2015 yılında geliştirilmiştir. O zamandan beri krizler için bir erken uyarı aracı olarak yaygın bir şekilde kullanılmaktadır. Test, Augmented Dickey-Fuller (ADF) model spesifikasyonuna dayanmakta ve birden fazla balonu tespit etmede ve bunların başlangıç ve bitiş tarihlerini belirlemede olağanüstü bir performans elde eden özyinelemeli bir algoritma kullanmaktadır (Phillips vd., 2015a). GSADF testi, fiyat balonlarını tanımlamak ve finansal zaman serisi verilerindeki patlayıcı davranışları tespit etmek için güçlü bir araçtır. Bu test, zaman içinde birden fazla balonun tanımlanmasını sağlayarak hisse senedi fiyatlarının dinamiklerini anlama noktasında çok önemli bir rol oynamaktadır. GSADF testinin, çeşitli hisse senedi piyasalarında uygulanması geçmiş ve gelecekteki fiyat düzeltmelerine işaret edebilecek fiyat balonlarını tespit etmedeki etkinliği vurgulanmıştır (Zeren ve Yılancı, 2019). Bu özellik, özellikle balon dinamiklerini anlayarak yatırım stratejilerini şekillendirebileceğinden Borsa İstanbul'da yıldız pazar ve ana pazarda işlem gören büyük şirketlere ait hisselerden oluşan XU100, XBANK ve XUSIN endeksleri için büyük önem taşımaktadır.

Korkmaz vd. (2016), Borsa İstanbul 100 Endeksi getiri oynaklığı üzerinde altın, döviz kuru ve mevduat faiz oranı gibi alternatif yatırım enstrümanlarındaki spekülatif fiyat artışlarının etkilerini incelemişlerdir. Ocak 2002-Mayıs 2016 dönemini kapsayan veri setini kullandıkları çalışmada, spekülatif fiyat artışlarının tespiti için SADF ve GSADF

testleri uygulanmış olup, dolar kurunda gözlemlenen fiyat balonlarının Borsa İstanbul 100 Endeksi oynaklığını artırdığı, ancak altın fiyatlarındaki balonların ise Borsa İstanbul 100 Endeksi oynaklığını azalttığı tespit edilmiştir. Akkaya (2018), Borsa İstanbul 100 Endeksi'ndeki fiyat balonlarının belirleyicilerini Ocak 2002-Mart 2017 dönemi için incelemiştir. RTADF testi kullanılarak belirlenen balon dönemlerinde, yurtdışı yerleşiklerin hisse senedi portföyü ile Borsa İstanbul 100 Endeksi balonları arasında istatistiksel olarak anlamlı bir ilişki tespit edilmiştir. Ayrıca, reel döviz kuru, ihracat, yurtdışı yerleşiklerin hisse senedi portföyü ve ABD doları aylık faiz oranından balonlara doğru nedensellik ilişkisi gözlemlenmiştir.

Yukarıda özetlenen bulgulara dayanarak GSADF testinin piyasa balonlarının varlığını tespit etmek için etkili bir yaklaşım olduğu açıktır. Dolayısıyla, bu çalışmada XU100, XBANK ve XUSIN endeks fiyat balonların varlığını tespit etmek için GSADF testi kullanılmıştır.

Makine öğrenimi algoritmalarının geleneksel zaman serisi analiz yöntemleriyle entegrasyonu, finansal balonların tespit ve tahmin süreçlerine yeni bir boyut kazandırmıştır. Özellikle, makine öğrenimi modellerinin GSADF testi gibi yapısal kırılma noktalarını tespit eden yöntemlerle birlikte kullanılması, daha güçlü ve kapsamlı analizler yapma imkânı sunmaktadır. Örneğin, makine öğreniminin GSADF ile entegrasyonu, geçmiş fiyat verilerini analiz eden ve kabarcık oluşumunu gösteren kalıpları belirleyen öngörücü modellerin geliştirilmesini kolaylaştırabilir. Ji vd. (2021) tarafından gerçekleştirilen çalışmada, GSADF modelinin geri yayılım ağı ile birleştirilerek XU100 gibi finansal endekslerdeki balon oluşumlarının daha doğru bir şekilde tahmin edildiği gösterilmiştir. Bu yaklaşım, geçmiş fiyat verilerindeki karmaşık ve doğrusal olmayan ilişkileri yakalayarak geleneksel istatistiksel yöntemlerin sınırlamalarını aşmaktadır. Makine öğrenimi algoritmalarının GSADF testi ile kullanımı, finansal balonların başlangıç ve bitiş zamanlarını daha kesin olarak belirlemek ve bu süreçlerin dinamiklerini daha iyi anlamak için değerli bir araç haline gelmektedir.

Finansal piyasaların karmaşık ve doğrusal olmayan yapısı, hisse senedi fiyat tahminlerini zorlu bir hale getirmektedir. Bu bağlamda, rassal orman algoritması, büyük veri kümelerini işleme ve karmaşık ilişkileri yakalama yeteneği sayesinde hisse senedi

fiyat tahmininde önemli bir potansiyel sunmaktadır. Çoklu karar ağacının bir araya getirilmesiyle oluşturulan bu yöntem, aşırı uyum sorununu en aza indirerek daha genellenebilir tahminler elde etmeyi mümkün kılmaktadır. Literatürdeki karşılaştırmalı çalışmalar, rassal orman algoritmasının, doğrusal regresyon ve destek vektör makineleri gibi geleneksel yöntemlere kıyasla hisse senedi fiyat tahminlerinde daha başarılı olduğunu göstermektedir (Nikou vd., 2019; Rouf vd., 2021). Rassal orman algoritmasının performansı, hiper parametre optimizasyonu ile daha da iyileştirilebilir. Özellikle, GSADF testi ile belirlenen balon dönemlerini içeren veri kümelerinde hiper parametre optimizasyonu, modelin piyasa dinamiklerine olan duyarlılığını artırarak daha doğru tahminler elde edilmesini sağlayabilir (Hoque ve Aljamaan, 2021). Bu sayede, rassal orman algoritması, finansal piyasalardaki yapısal kırılmaları daha iyi modelleyerek yatırım kararlarının alınmasında önemli bir araç haline gelebilir. Tran vd., (2023) 2001'den 2021'e kadar Vietnam borsasındaki finansal balonları tespit ve tahmin etmek için, sağ kuyruklu birim kök testini içeren PSY prosedürünü kullanmışlardır. Daha sonra gerçek zamanlı finansal balon olaylarını tahmin etmek için makine öğrenimi algoritmaları kullanılmışlar ve 2006-2007 ve 2017-2018 dönemlerinde Vietnam borsasında finansal balonların varlığını ortaya koymuştur. Ek olarak ampirik kanıtlar, Vietnam borsasındaki finansal balonları tahmin etmede rassal orman ve yapay sinir ağı algoritmalarının geleneksel istatistiksel yöntemlere göre üstün performansını desteklemiştir.

Makroekonomi literatüründe, hisse senedi piyasalarındaki finansal balonların tespiti amacıyla makine öğrenmesi yöntemlerinin kullanımı görece yeni ve gelişmekte olan bir yaklaşımdır. Finansal krizlere ilişkin mevcut çalışmaların büyük bir kısmı, doğrudan balon oluşumlarını öngörmekten ziyade, bankacılık sektörü, menkul kıymet piyasaları ve kamu borcu gibi alanlarda genel ekonomik krizlerin erken uyarı sistemlerine odaklanmaktadır. Bu nedenle, finansal balonların tahmini özelinde yapılan araştırmalar sınırlı kalmış ve bu alan, veri odaklı modern yöntemlerin uygulanabileceği önemli bir boşluk olarak dikkat çekmektedir. Başoğlu Kabran ve Ünlü (2021), S&P 500 hisse senedi piyasasındaki balonları, gerçek zamanlı balon tespit testi ve destek vektör makinesi (DVM) kullanan iki aşamalı bir makine öğrenimi yaklaşımıyla tahmin etmiştir. İki adımdan oluşan analizde önce sağ kuyruklu birim kök testi kullanılarak S&P 500

endeksindeki balonların tespit edilmiş, daha sonra ise balonları makroekonomik göstergelere göre tahmin etmek için DVM kullanılmıştır. Sonuçta, yüksek tahmin gücüne sahip önerilen yaklaşımın balon tahmininde uygun bir alternatif olabileceğini belirtmişlerdir.

Makroekonomik değişkenlerin gelişmekte olan ülkelerdeki hisse senedi piyasaları üzerindeki etkileri de araştırmacılar arasında ilgi görmüştür. Finansal balonlar üzerinde etkili olan makroekonomik faktörleri inceleyen Sağlam Bezgin ve Başar (2020) çalışmalarında, Türkiye'de BIST 100 endeksi üzerinden 1997-2018 yılları arasında finansal balon oluşumlarını ve bu oluşumları etkileyen makroekonomik faktörleri incelemişlerdir. GSADF testi ile Ocak 2000, Aralık 2007 ve Şubat 2018 yıllarında önemli finansal balonların oluştuğu tespit edilmiştir. Bu balonların oluşumunda faiz oranı, M2 para arzı ve kredi hacmi gibi makroekonomik değişkenlerin etkili olduğu, Hatemi-J asimetrik nedensellik testi ile ortaya konmuştur. Bir diğer çalışmada, para politikasının varlık fiyat balonları üzerindeki etkisi deneysel ortamlarda araştırılmış ve faiz oranı ayarlamaları gibi proaktif para politikası önlemlerinin, yatırımcı beklentilerini ve davranışlarını etkileyerek büyük balonların oluşumunu azaltabileceği bulunmuştur (Hennequin ve Hommes, 2023). Bu bulgu, stratejik müdahalelerin fiyatları istikrara kavuşturabileceğini gösterdiğinden, XU100, XBANK ve XUSIN gibi endeksleri izleyen finansal kurumlar ve politika yapıcılar için özellikle önemlidir.

Bu araştırma, finansal balonların tespiti ve tahmini alanında, makine öğrenmesi tekniklerinin sahip olduğu metodolojik avantajlardan yararlanarak mevcut literatüre nitelikli katkılar sunmaktadır. Geleneksel istatistiksel yaklaşımların sınırlılıklarına kıyasla, makine öğrenmesi yöntemleri doğrusal olmayan, karmaşık veri yapılarının analizine olanak tanımakta ve bu yönüyle daha esnek ve etkili modeller geliştirilmesini mümkün kılmaktadır. Literatürdeki mevcut çalışmaların büyük ölçüde makroekonomik göstergeler ile hisse senedi getirileri arasındaki doğrusal ilişkileri incelemiş olması dikkate alındığında, bu çalışma söz konusu değişkenler ile BIST endeks getirileri arasındaki doğrusal olmayan ilişkileri parametrik olmayan bir çerçevede ele alarak literatürdeki önemli bir boşluğu doldurmaktadır. Araştırma, katkılarını çok boyutlu biçimde genişletmektedir. İlk olarak, finansal balonların tespiti sürecinde GSADF testi ile

makine öğrenmesine dayalı rassal orman algoritması bir arada uygulanmıştır. İkinci olarak, çalışmada çoğunlukla kullanılan günlük verilerin aksine, 2002:01 – 2024:06 dönemine ait aylık frekansta daha uzun bir zaman serisi kullanılmıştır. Son olarak, analiz kapsamında sepet kur, TÜFE, ÜFE, çekirdek enflasyon, para arzı, FED politika faizi, uluslararası rezervler, bileşik öncü göstergeler endeksi, jeopolitik risk endeksi ile mevduat ve kredi faizleri gibi kapsamlı makroekonomik değişkenler değerlendirilmiştir. Bu yaklaşım sayesinde, finansal balonların oluşum dinamiklerine ilişkin daha derinlemesine bir anlayış geliştirilmektedir ve söz konusu bulgular hem politika yapıcılar hem de yatırımcılar için anlamlı içgörüler sunmaktadır.

1.2. YÖNTEM

1.2.1. GSADF Testi

Phillips vd. (2015a), SADF yönteminin sınırlamalarını aşmak için, PSY prosedürü olarak da adlandırılan Genelleştirilmiş Sup ADF (GSADF) testini geliştirmiştir. GSADF testi, örnek dizilerde patlayıcı kalıpları tespit etmeyi amaçlayan yuvarlanan pencere SADF testine dayalı, sağ kuyruklu ADF testinin yinelemeli bir uygulamasıdır. SADF'ye kıyasla, GSADF yuvarlanan pencereler açısından daha esnektir ve bu da fiyat patlaması davranışını incelemek ve piyasa balonlarının varlığını doğrulamak için değerli bir araç haline getirmektedir. Borsa İstanbul endeks fiyat serilerindeki balonları tespit edebilmek amacıyla Genelleştirilmiş Sup ADF (GSADF) testi kullanılmıştır. Genelleştirilmiş Supremum Dickey Fuller (GSADF) testi, toplam gözlem sayısının alt örneklemleri için özyinelemeli olacak şekilde tekrarlanan ADF testi regresyonlarına dayanmaktadır (Ural, 2022). GSADF test istatistiğinin elde edilmesi için, ADF test regresyonu aşağıdaki şekilde tahmin edilmektedir:

$$\Delta y_t = \widehat{\alpha}_{r_1,r_2} + \widehat{\beta}_{r_1,r_2} y_{t-1} + \sum_{i=1}^{k} \widehat{\psi}^{i}_{r_1,r_2} \Delta y_{t-i} + \widehat{\varepsilon}_t \qquad (1)$$

Burada y_t, t zamanındaki ilgili borsa endeks fiyatlarını, Δ ise birinci fark operatörünü ifade etmektedir. Olası bir otokorelasyonu önlemek için $i = 1, 2, \ldots, k$, Δy

'nin gecikmeleri denklemin sağ tarafına dahil edilmiştir. r_1 ve r_2 alt simgeleri, alt örneklemin başlangıç ve bitiş noktalarını göstermektedir (Phillips vd., 2015a).

Birim kökün sıfır hipotezi ($H_o: \beta_{r_1,r_2} = 0$) patlayıcı davranış alternatifine ($H_1: \beta_{r_1,r_2} > 0$) karşı $ADF_{r_1}^{r_2} = \hat{\beta}_{r_1,r_2} / s.e.\left(\hat{\beta}_{r_1,r_2}\right)$ istatistiği kullanılarak test edilmektedir. Burada s.e. eğim katsayısının standart hatasını göstermektedir.

GSADF test istatistiğini elde etmek için hem r_1 hem de r_2 'yi değiştirerek tüm alt örneklemler için $ADF_{r_1}^{r_2}$ test istatistikleri hesaplanmaktadır:

$$GSADF(r_0) = \sup_{r_2 \in [r_0, 1],\ r_1 \in [0,\ r_2 - r_0]} ADF_{r_1}^{r_2} \tag{2}$$

Burada r_0, $r_0 = 0.01 + 1.8/\sqrt{T}$ şeklinde elde edilen başlangıç alt örneklem boyutunu, T ise gözlem sayısını göstermektedir, yani ilk gözlem 0 ile $r_2 - r_0$ arasında değişirken, son gözlem r_0 ile 1 arasında değişmektedir. Kritik değerleri elde etmek için Phillips ve Shi'nin (2020) önerisini izleyerek bootstrap simülasyonları kullanılmıştır. GSADF test istatistiği, her bir gözlem için 1000 adet Bootstrap ve Monte Carlo simülasyonu kullanılarak elde edilmiş olup, %95 güven düzeyinde kritik değerler dikkate alınmıştır. Sıfır hipotezinin reddedilmesi, seride en az bir balon olduğunu göstermekte olup hipotezler aşağıda yer almaktadır.

H_0: BIST Pay endekslerinde finansal balon bulunmamaktadır.

H_1: BIST Pay endekslerinde finansal balon bulunmaktadır.

Balon varlığı tespiti sonrasında ise balon oluşum dönemleri geriye dönük SADF (BSADF) istatistik dizileri yardımıyla belirlenmektedir. BSADF istatistik dizileri geriye doğru (backwards) genişleyen yapıdaki örneklemler için sağ kuyruklu ADF testleri kullanılarak elde edilmektedir (Ural, 2022). BSADF istatistiği ve buna bağlı olarak GSADF istatistiği sırasıyla aşağıdaki gibi yazılabilir (Caspi, 2017):

$$\left\{BSADF_{r_2}(r_0)\right\}_{r_2 \in [r_0, 1]} \tag{3}$$

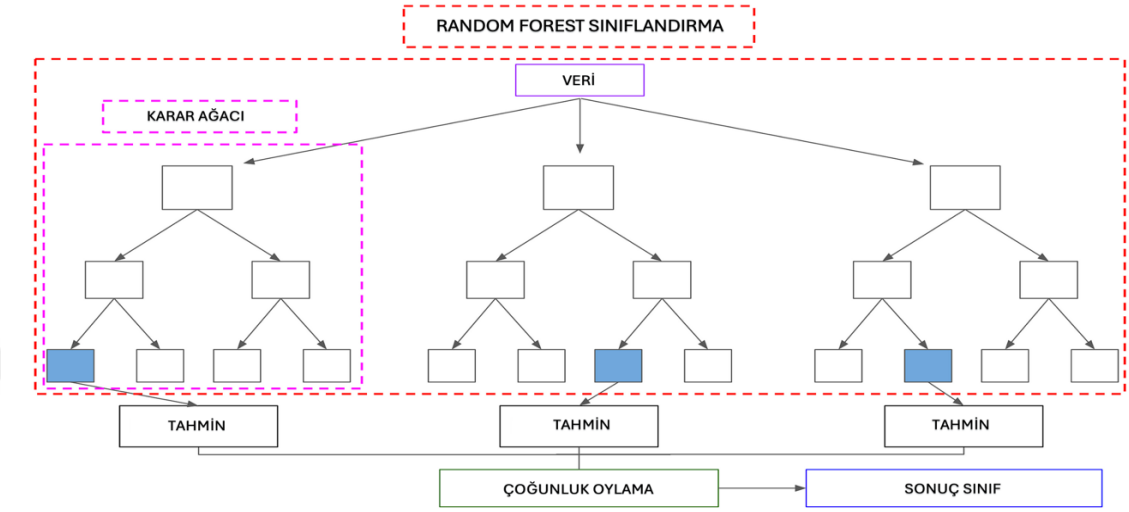
$$GSADF(r_0) = \sup_{r_2 \in [r_0, 1]} \left\{BSADF_{r_2}(r_0)\right\} \tag{4}$$

Oluşturulan BSADF dizileri ile Monte Carlo simülasyonuyla hesaplanan sağ kuyruklu kritik değerler karşılaştırılarak baloncukların oluşum tarihleri tespit edilmektedir.

1.2.2. Rassal Orman

Rassal orman algoritmasının birçok çeşidi vardır. Ancak günümüzde kullanılan en yaygın olanı Breiman (2001) tarafından geliştirilen rassal orman (random forest) algoritması, karar ağacı (decision tree) algoritmalarından oluşan bir topluluk öğrenmesi (ensemble learning) yöntemi olarak tanımlanmaktadır. Denetimli bir makine öğrenimi algoritması olan rassal orman birden fazla sınıflandırıcıyı birleştiren bir teknik olan topluluk öğrenimini kullanır. Temel olarak rassal orman yönteminin amacı, tek bir karar ağacı üretmek yerine her biri farklı eğitim setlerinde ele alınmış çok sayıda ağacın kararlarını birleştirmektir (Çağlayan Akay, 2020). Rassal orman algoritması, makine öğrenimi alanında, özellikle sınıflandırma ve regresyon problemlerinde sıklıkla tercih edilen güçlü bir yöntemdir. Avantajlarına bakıldığında, algoritmanın başarısı hem örneklem hem de özellik seçimi aşamalarında uyguladığı rastgelelik ilkesine dayanmaktadır. Bu sayede, aşırı öğrenme problemi minimize edilir ve modelin genelleme yeteneği artırılır. Ayrıca, algoritmanın çoklu karar ağaçlarından oluşması, modelin gürültülü verilere karşı daha dayanıklı olmasını sağlar. Özellik önemi analizinde de kullanılabilen bu yöntem, yüksek boyutlu veri setlerinde bile başarılı sonuçlar verir. Dahası, algoritmanın ölçeklenebilirliği, büyük veri kümelerindeki uygulamaları için oldukça avantajlıdır. Son olarak rassal orman algoritmasının hem sayısal hem de kategorik verilerle çalışabilme özelliği, uygulamaların çeşitliliğini artırır. Bu özellikler sayesinde, rassal orman algoritması, birçok farklı alanda başarılı bir şekilde kullanılmaktadır. Rassal orman sınıflandırıcısının örnek bir çizimi Şekil 1'de yer almaktadır.

Şekil 1: Rassal Orman (Random Forest) Sınıflandırıcısı



Kaynak: Yazar tarafından oluşturulmuştur.

Rassal orman algoritması çeşitli avantajlar sunmakla birlikte, bazı sınırlılıkları da beraberinde getirmektedir. Bu yöntemle ilişkili en temel dezavantajlardan biri, yüksek hesaplama maliyetidir. Çok sayıda karar ağacından oluşan bir modelin eğitilmesi ve her bir yeni gözlem için tahmin üretilmesi, özellikle büyük veri setlerinde işlem süresini uzatmakta ve kaynak tüketimini artırmaktadır. Ayrıca, her ne kadar rassal orman algoritması aşırı uyum (overfitting) sorununa karşı görece dirençli olsa da, bu probleme tamamen bağışık değildir. Özellikle örneklem büyüklüğünün sınırlı olduğu veya modelin fazlaca karmaşıklaştırıldığı durumlarda, algoritma eğitim verilerine aşırı derecede uyum sağlayarak genelleme yeteneğini zayıflatabilir. Bununla birlikte, yeterli sayıda ağaç kullanılması durumunda bu risk azaltılabilir ve modelin doğrulama performansı önemli ölçüde iyileştirilebilir.

Rassal orman sınıflandırıcısı, verilen veri kümesinden öğrenerek, eğitilen modele dayalı biçimde yeni gözlemleri belirli sınıf etiketlerine atamaktadır. Balon var veya balon yok, evet veya hayır, 0 veya 1, gibi sınıf etiketlerini çıktı olarak tahmin etmektedir. Bu süreçte, modelin sınıflandırma performansı; Doğru Pozitif (DP), Yanlış Pozitif (YP), Doğru Negatif (DN) ve Yanlış Negatif (YN) değerleri temel alınarak çeşitli değerlendirme ölçütleriyle analiz edilmektedir. Bu ölçütler arasında doğruluk oranı, kesinlik (precision),

duyarlılık (recall), özgüllük (specificity), F1 skoru ve AUC değeri gibi metrikler yer almakta olup, modelin sınıflandırma başarımını çok boyutlu bir perspektiften değerlendirmeye olanak tanımaktadır.

1.3. UYGULAMA

1.3.1. Balonların Tespiti

Çalışmanın ilk aşamasında, Borsa İstanbul 100 (BIST100), Bankacılık (XBANK) ve Sınai (XUSIN) endekslerinde 2002 yılından itibaren spekülatif balonların varlığı ile bu balonların ortaya çıktığı dönemlerin belirlenmesi amaçlanmıştır. Bu doğrultuda, Phillips, Shi ve Yu (2015) tarafından geliştirilen sağ kuyruklu birim kök testi olan GSADF yöntemi kullanılmıştır. Analiz kapsamında 2002M01 – 2024M06 dönemine ait aylık kapanış verileri değerlendirilmiş olup, ilgili veriler *Investing.com* veri tabanından temin edilmiştir. GSADF uygulaması R programlama dilinde yapılmıştır (García vd., 2021). Rassal orman algoritması ise Python programlama dili kullanılarak Spyder IDE ortamında oluşturulmuştur.

Tablo 1'de yer alan Tüketici fiyatları endeksi, Çekirdek TÜFE, üretici fiyatları endeksi, uluslararası rezervler, kredi faizi, TL üzerinden açılan mevduatlara uygulanan faiz EVDS'den alınmıştır. Türkiye Cumhuriyet Merkez Bankası (TCMB) ile Ekonomik Kalkınma ve İşbirliği Örgütü (OECD) ortak çalışması sonucunda oluşturulan ve 2002 tarihinden bu yana aylık olarak yayınlanan bileşik öncü göstergeler endeksi (BOGE) ise yine EVDS'den temin edilmiştir. Sepet Kur, USD/TL Döviz Kuru ve EUR/TL Kuru verileri ile ortalama alınarak yazar tarafından oluşturulmuştur. M2 para arzı International Financial Statistics (IFS), ABD politika faiz oranı Federal Reserve Economic Data veri tabanları kullanılarak elde edilmiş, ilgili ülkeye ait jeopolitik riskleri ölçen Jeopolitik Risk Endeksi (GPRC) ise https://www.policyuncertainty.c-om/gpr.html sitesinden Türkiye için alınmıştır.

Tablo 1: Dışsal Değişkenlerin Kategorileri

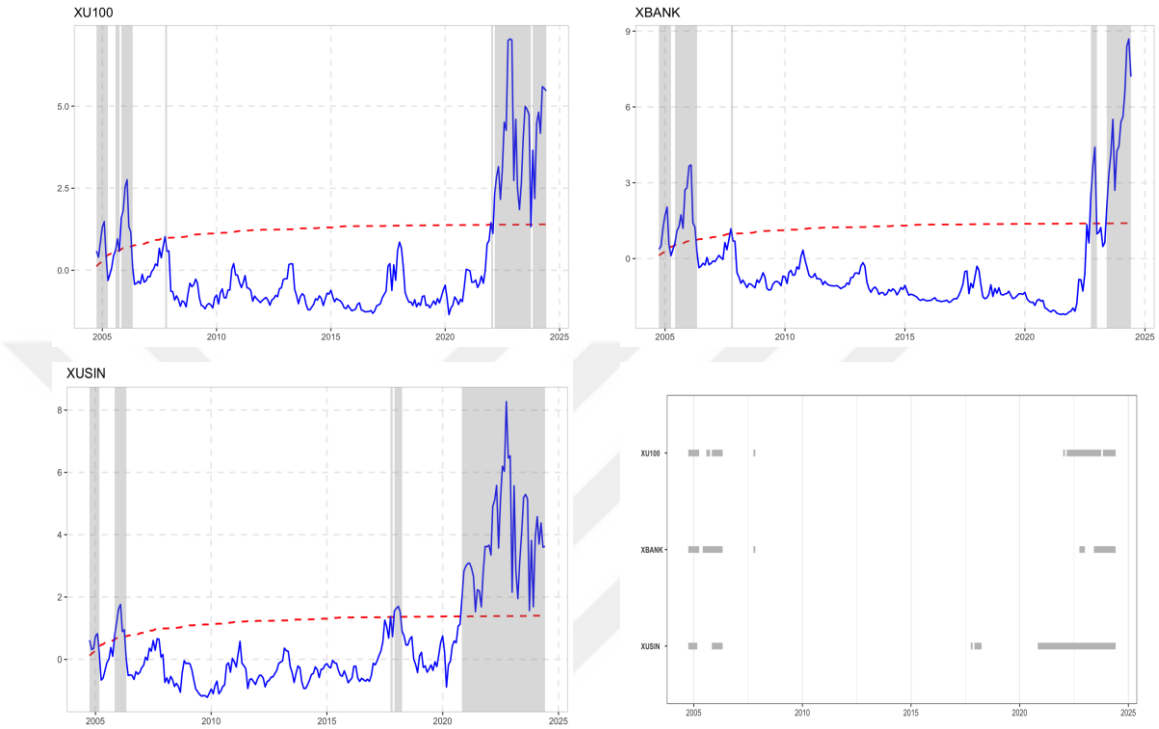
Dışsal Değişkenlerin Kategorileri	
Makroekonomik Göstergeler	***Finansal Göstergeler***
Sepet Kur	Mevduat Faizi
Uluslararası Rezervler	Kredi Faizi
M2 Para Arzı	GPRC_TUR
BOGE	FEDFUNDS
TÜFE	
Cektüfe	
ÜFE	

Kaynak : Yazar tarafından oluşturulmuştur.

BIST 100, BIST Sınai ve BIST Banka fiyat endekslerinde olduğu gibi, çalışmada yer alan tüm dışsal makroekonomik değişkenler de aylık frekansta değerlendirilmiştir. Tablo 2, GSADF test istatistiklerini ve ilgili bootstrap kritik değerlerini göstermektedir. Tablo 2'de raporlanan test istatistikleri incelendiğinde, %1 anlamlılık düzeyinde, BIST pay endekslerinde finansal balon bulunmadığını öne süren H_0 hipotezinin reddedildiği görülmektedir. Bu doğrultuda, GSADF testinden elde edilen bulgular, XU100, XBANK ve XUSIN endekslerinde dönemsel olarak spekülatif nitelikte finansal balonların varlığını ortaya koymaktadır.

GSADF testi aynı zamanda, incelenen endekslerdeki fiyat balonlarının zamansal sınırlarını ortaya koymak amacıyla kullanılmış; bu doğrultuda balon oluşumlarının başlangıç ve sona erdiği tarihler belirlenmiştir. Söz konusu dönemler, Şekil 2'de endeks bazında görsel olarak temsil edilmektedir.

Şekil 2: Endeksler için GSADF Test Sonuçları ve Balon Dönemlerinin Toplu Gösterimi



Kaynak : Yazar tarafından oluşturulmuştur.

Not: Gölgeli alanlar balon dönemlerini temsil etmektedir.

Tablo 2: GSADF Test İstatistikleri ve Kritik Değerler

Değişken	Test İstatistiği	Kritik Değerler			Fiyat Balonu
		1%	5%	10%	
XU100	7,05	2,47	2,06	1,82	Var
XBANK	8,69	2,08	1,36	1,1	Var
XUSIN	8,27	2,47	2,06	1,82	Var

Kaynak : Yazar tarafından oluşturulmuştur.

Tablo 3'te incelenen dönem içerisindeki endeks fiyatlarına bakıldığında BIST 100 endeksinde yedi balon dönemi yaşanırken BIST Banka ve BIST Sınai endeksinde daha az balon dönemi geçirmektedir. Bununla birlikte, aylar bazında ele alındığında ise XUSIN,

XU100 ve XBANK endeksinden daha uzun ve devam etmekte olan balon dönemi sunmaktadır. BIST 100 endeksindeki ilk balon dönemleri nispeten daha kısa süreli iken 2022-2023 arasındaki 19 ay süren balon ve 2023 sonunda başlayıp 2024 ilk yarı dönemini tamamlayan balon daha uzun süreli olarak gerçekleşmiştir. Öte yandan, BIST Sınai ve BIST Banka endeksindeki fiyat balonları 5 balon dönemine sahiptir. Endekslerde meydana gelen balon dönemlerinin toplu gösterimine bakıldığında ise çoğunlukla eşanlı balon dönemi yaşandığı tespit edilmiştir.

Tablo 3: Balon Dönemleri

XU100		
Başlangıç	**Zirve**	**Bitiş**
1.10.2004	1.02.2005	1.04.2005
1.08.2005	1.09.2005	1.10.2005
1.11.2005	1.02.2006	1.05.2006
1.10.2007	1.10.2007	1.11.2007
1.01.2022	1.01.2022	1.02.2022
1.03.2022	1.11.2022	1.10.2023
1.11.2023	1.04.2024	1.06.2024
XBANK		
Başlangıç	**Zirve**	**Bitiş**
1.10.2004	1.02.2005	1.04.2005
1.06.2005	1.02.2006	1.05.2006
1.10.2007	1.10.2007	1.11.2007
1.10.2022	1.12.2022	1.01.2023
1.06.2023	1.05.2024	1.06.2024
XUSIN		
Başlangıç	**Zirve**	**Bitiş**
1.10.2004	1.02.2005	1.03.2005
1.11.2005	1.02.2006	1.05.2006
1.10.2017	1.10.2017	1.11.2017
1.12.2017	1.02.2018	1.04.2018
1.11.2020	1.10.2022	1.06.2024

Kaynak: Yazar tarafından oluşturulmuştur.

1.3.2. Rassal Orman Sonuçları

İlgili dönemde endeks fiyatlarında balon oluşumlarının öngörülebilmesi amacıyla, veri seti rastgele bir biçimde eğitim ve test olmak üzere iki alt kümeye ayrılmıştır. Bu kapsamda, gözlemlerin %80'i eğitim verisi, kalan %20'si ise test verisi olarak kullanılmıştır. Sınıflandırma modeli, bağımlı değişkenin Borsa endekslerinde balon oluşumunu balon var ve balon yok şeklinde ikili kategorilerle temsil ettiği bir yapı üzerine kurulmuştur. Modelin sınıflandırma yapısı, Breiman vd. (1984) tarafından geliştirilen karar ağaçları yöntemine dayanan Rassal Orman algoritmasının yöntemsel çerçevesine uygun biçimde tasarlanmıştır. Bu çerçeveye göre eşitlik 5'te bir ağaçtaki her m ağaç durağının (node) çeşitlilik (impurity) ölçütü bir Gini endeksi (G_m) biçiminde tanımlanmıştır:

$$G_m = \sum_{k=1}^{K} p_{mk}\left(1 - p_{mk}\right) \quad (5)$$

$$p_{mk} = \frac{1}{N_m} \sum_{i \in D_m} 1\left(y_i = k\right) \quad (6)$$

Eşitlik 6'da yer alan p_{mk} terimi m'inci ağaç durağında i endeksi için gözlenen çıktının (y_i) "Balon var" ve "Balon yok" sınıflarından birisi olan k sınıfına (k = 1, ..., K) denk gelme oranını ifade etmektedir. D_m terimi m'inci durağa karşılık gelen veri kümesini ifade ederken N_m ise bu verilerin sayısını belirtmektedir. G_m Terimi ise m durağında her bir k sınıfı için k sınıfına ait olan ve ait olmayan gözlemlerin oranlarının çarpımlarının toplamından oluşur. Bu nedenle G_m ne kadar düşük ise m durağındaki gözlemler o kadar birbirine benzemektedir (James vd., 2013). Bu çalışmada BIST 100, BIST Banka ve BIST Sınai fiyatlarında balon bulunan ve bulunmayan endeks "Balon var" ve "Balon yok" şeklinde iki sınıfta gruplandığı için G_m terimi $2p_{m_1}\left(1 - p_{m_1}\right)$ olarak hesaplanabilir

Çalışmada BIST 100, BIST Banka ve BIST Sınai endekslerindeki patlayıcı fiyat balonlarının nedenlerini tespit ve tahmin etmek için ampirik bir strateji uygulanmıştır.

1.3.3. Rassal Orman Performans Ölçütleri (Başarısı)

Makine öğrenmesi uygulamalarında performans değerlendirme ölçütleri, modellerin başarısını anlamak ve farklı modelleri karşılaştırmak açısından büyük önem taşımaktadır. Bu çalışmada, rassal orman algoritmasının sınıflandırma performansını değerlendirmek amacıyla çeşitli ölçütlerden yararlanılmıştır. Söz konusu metrikler; doğruluk oranı, kesinlik (precision), duyarlılık (recall), özgüllük (specificity), F1 skoru ve AUC (Area Under the Curve) değerinden oluşmaktadır. Her bir endeks için örneklem verisi, öğrenme ve test kümelerine ayrıldıktan sonra, rassal orman algoritması çok sayıda karar ağacı oluşturarak fiyat balonu oluşumuna ilişkin tahminlerde bulunmakta ve bu tahminler, test verisi üzerindeki gerçek değerlerle karşılaştırılmaktadır. Bu doğrultuda, kullanılan değerlendirme ölçütleri, modelin tahmin performansını objektif biçimde yansıtarak analizdeki model kalitesinin temel göstergelerini oluşturmaktadır. Bu ölçütlerin formülasyonları eşitlik 7, 8, 9, 10 ve 11'de verilmektedir (Uğuz, 2019):

$$Doğruluk = \frac{DP+DN}{DP+DN+YP+YN} \quad (7)$$

$$Özgüllük = \frac{DN}{DN+YP} \quad (8)$$

$$Kesinlik = \frac{DP}{DP+YP} \quad (9)$$

$$Duyarlılık = \frac{DP}{DP+YN} \quad (10)$$

$$F1\ Skoru = 2 * \frac{Duyarlılık * Kesinlik}{Duyarlılık + Kesinlik} \quad (11)$$

Söz konusu değerlendirme ölçütleri kullanılarak oluşturulan Tablo 4, her bir endeks bazında rassal orman modelinin tahmin performansını ortaya koymaktadır. Elde edilen bulgular, rassal orman algoritmasının Borsa İstanbul endekslerindeki fiyat balonlarını açıklamada etkili olduğunu ve balon oluşumuna katkı sağlayan potansiyel belirleyicileri başarıyla yakalayabildiğini göstermektedir.

Tablo 4: Tahmine Dayalı Performans Ölçütleri

Ölçüt	XU100	XBANK	XUSIN
Doğruluk	0,963	0,926	0,926
Kesinlik	0,818	0,8	0,9
Duyarlılık	1	0,571	0,75
Özgüllük	0,956	0,979	0,976
F1 Puanı	0,9	0,667	0,818
AUC	0,974	0,985	0,986

Kaynak: Yazar tarafından oluşturulmuştur.

Hata matrisi, bir sınıflandırıcının iki farklı sınıf etiketlerini ne ölçüde sınıflandırabildiği ile ilgili performansını gösteren bir analiz aracıdır. Doğru pozitif (DP) ve doğru negatif (DN) doğru tahminlere karşılık gelirken, yanlış pozitif (YP) ve yanlış negatif (YN) yanlış tahminlere karşılık gelir (Metz, 1978). Tablo 5, BIST endeksleri erken uyarısı için karışıklık matrisini ifade etmektedir.

Tablo 5: BIST Endeksleri Erken Uyarısı İçin Karışıklık Matrisi

Gerçek \ **Tahmin Edilen**	**0: Balon Yok**	**1: Balon Var**
0: Balon Yok	Doğru Negatif (DN)	Yanlış Pozitif (YP)
1: Balon Var	Yanlış Negatif (YN)	Doğru Pozitif (DP)

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 3'te sunulan karışıklık (hata) matrisi, XU100 endeksi için Rassal Orman algoritmasının sınıflandırma performansına ilişkin önemli bulgular ortaya koymaktadır. Modelin 'balon yok' durumunu doğru tahmin etme başarısı, 43 adet doğru negatif (DN) ile oldukça yüksektir. Benzer şekilde, 9 doğru pozitif (DP) değeri ile 'balon var' durumlarını da isabetli şekilde tespit ettiği gözlemlenmektedir. Yanlış pozitif (YP) sayısının yalnızca 2 olması, modelin balon olmadığı hâllerde hatalı biçimde balon var sonucuna ulaşma olasılığının oldukça düşük olduğunu göstermektedir. Ayrıca, yanlış negatif (YN) sayısının

sıfır olması, modelin balon var iken bu durumu atlamadığını, dolayısıyla yüksek bir duyarlılığa sahip olduğunu göstermektedir. Bu sonuçlar, modelin özellikle ‘balon var’ sınıfında hataya çok az düştüğünü ve genel anlamda dengeli bir performans sergilediğini ortaya koymaktadır.

Şekil 3: Balon Varlığını Tahminleyen Karışıklık Matrisi Sonuçları



Kaynak: Yazar tarafından oluşturulmuştur.

XBANK endeksine ilişkin karışıklık matrisi incelendiğinde, modelin 46 DN ile ‘balon yok’ durumlarını büyük ölçüde doğru sınıflandırdığı görülmektedir. Bu durum, modelin yanlış pozitif oranının düşük olduğuna işaret etmektedir. Öte yandan, yalnızca 4 DP ile ‘balon var’ durumlarını sınırlı sayıda doğru tahmin edebilmiş, 3 gözlemde ise balon var iken ‘balon yok’ şeklinde hatalı sınıflandırma yapmıştır. Bu durum, modelin balonlu dönemlerdeki duyarlılığının (sensitivity) XU100’e kıyasla daha zayıf olduğunu ve iyileştirme potansiyeli bulunduğunu göstermektedir.

XUSIN endeksi için elde edilen sonuçlara göre, model 41 DN ile ‘balon yok’ durumlarını yüksek doğrulukla tahmin etmiş, 9 DP ile ‘balon var’ durumlarını da başarıyla belirlemiştir. Ancak, 3 YN değeri ile bazı balonlu dönemleri atladığı görülmektedir. Bununla birlikte, YP sayısının oldukça düşük olması, balon olmayan dönemlerdeki yanlış sınıflandırmaların sınırlı olduğunu göstermektedir. Dolayısıyla, XUSIN için geliştirilen model hem ‘balon var’ hem de ‘balon yok’ durumlarında genel olarak başarılı bir

performans sergilemekle birlikte, yanlış negatiflerin azaltılması, modelin balon tespit duyarlılığını artırma açısından faydalı olacaktır.

Sınıflandırma algoritmalarının performans değerlendirmesinde yaygın olarak kullanılan doğruluk oranı (accuracy), bir modelin genel başarımını ölçen temel metriklerden biridir ve doğru sınıflandırılan gözlem sayısının toplam tahmin sayısına oranı olarak tanımlanır. Yüksek doğruluk oranı, modelin tahmin gücünün genel olarak güçlü olduğunu göstermektedir. Bu bağlamda, çalışmada kullanılan rassal orman sınıflandırıcısının doğruluk oranı XU100 endeksi için %96,3; XBANK ve XUSIN endeksleri için ise %92,6 olarak hesaplanmıştır. Bu bulgular, modelin endeks fiyatlarındaki balon oluşumlarını belirlemede yüksek doğrulukla çalıştığını ve güçlü bir genel performans sergilediğini ortaya koymaktadır. Bununla birlikte, doğruluk oranının yüksek olması, model başarımının mutlak göstergesi değildir. Özellikle sınıf dağılımının dengesiz olabildiği durumlarda, modelin duyarlılık, özgüllük, kesinlik ve F1 skoru gibi diğer performans ölçütleriyle birlikte değerlendirilmesi, daha bütüncül ve sağlıklı bir analiz yapılmasına olanak tanımaktadır.

Kesinlik (precision) metriği, sınıflandırıcı modelin pozitif sınıf olarak tahmin ettiği örnekler arasında gerçekte de pozitif olanların oranını ifade eder. Bu ölçüt, özellikle yanlış pozitif tahminlerin etkisini değerlendirmek açısından önem taşımaktadır. Kesinlik değeri ne kadar yüksekse, modelin gerçekte balon olmayan durumları hatalı biçimde ‘balon var’ şeklinde sınıflandırma olasılığı o denli düşüktür. Bu yönüyle kesinlik, doğru biçimde sınıflandırılan balonlu dönemlerin oranını değerlendirmek amacıyla kullanılmaktadır. Çalışma kapsamında elde edilen bulgulara göre, kesinlik değeri XU100 için 0,818; XBANK ve XUSIN endeksleri için ise sırasıyla 0,800 ve 0,900 olarak hesaplanmıştır. Bu sonuçlar, özellikle XUSIN endeksinde modelin pozitif sınıflamaları oldukça isabetli biçimde gerçekleştirdiğini göstermektedir.

Duyarlılık (hassasiyet ya da hatırlama), pozitif sınıfa ait örneklerin doğru şekilde tahmin edilme oranını ifade eder ve bir sınıflandırıcının gerçek pozitif örnekleri ne ölçüde başarılı bir şekilde belirlediğini ölçmek için kullanılır. Yüksek duyarlılığa sahip bir model, yanlış negatif oranı düşük olan ve pozitif sınıftaki örnekleri isabetli şekilde tanımlayabilen bir modeldir. XU100 endeksi için duyarlılık değeri 1 olarak hesaplanmış olup, bu durum

modelin balon var olan tüm fiyat dönemlerini eksiksiz biçimde doğru olarak sınıflandırdığını göstermektedir. Bu kapsamda, pozitif sınıfta yer alıp yanlış sınıflanan herhangi bir örnek bulunmamaktadır; dolayısıyla modelin XU100 endeksindeki tahmin başarımı oldukça yüksektir.

Özgüllük, bir sınıflandırıcının reddedilmesi gereken tüm durumları reddetme yeteneği olarak tanımlanmaktadır. Mükemmel bir sınıflandırıcı tüm doğru negatifleri reddetmekte ve beklenmeyen sonuçlar vermemektedir. Uygulamada ise genellikle herhangi bir sınıflandırıcı, reddedilmesi gereken bazı durumları seçmekte ve bu nedenle bazı yanlış pozitif değerlere sahip olmaktadır. Performans sonuçlarına göre, sınıflandırıcının XU100, XBANK ve XUSIN için özgüllük değeri sırasıyla 0,956, 0,979 ve 0,976'dır. Özgüllük ölçütüne göre tahminleyici sınıflandırıcı model negatif sınıfları doğru tahmin etmede yüksek bir başarı göstermektedir. Yani gerçekte balon olmadığı halde sınıflandırıcının balon olduğunu belirten yanlış pozitif örnek oranı düşük olup, modelin yüksek bir başarı göstermiş olduğunu belirtmektedir.

F1 skoru, duyarlılık ve kesinlik ölçütlerinin harmonik ortalamasını temsil eder ve dengesiz sınıf dağılımlarında model performansını değerlendirmek için etkili bir metriktir. F1 skoru, en iyi durumda 1, en kötü durumda 0 değerini alır. Bu çalışmada incelenen tüm endeksler için F1 skorlarının ortalamanın üzerinde olduğu görülmekte ve bu durum, rassal orman modelinin dengeli ve güçlü bir sınıflandırma performansı sergilediğine işaret etmektedir.

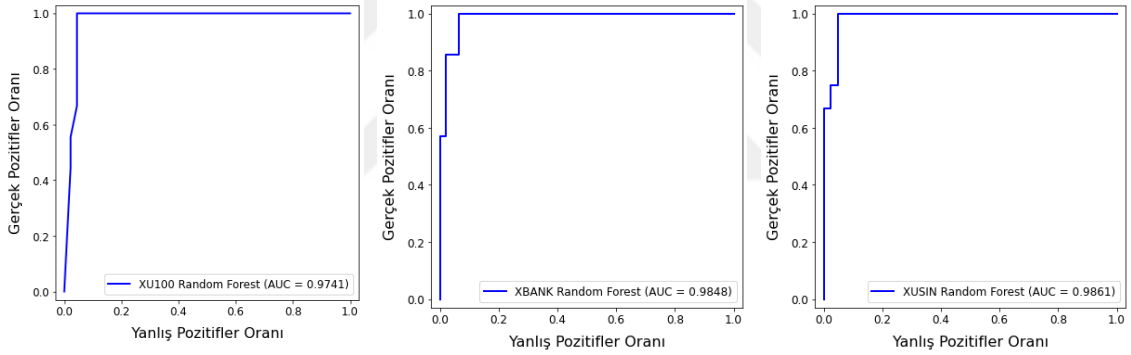
Bir ROC eğrisi (Receiver Operating Characteristic Curve-Alıcı İşletim Karakteristik Eğrisi), tüm sınıflandırıcı modelinin performansını duyarlılık ve özgüllüğü dikkate alarak gösteren bir grafiktir. ROC eğrisi, modelin farklı sınıflandırma eşiklerinde doğru pozitiflerin oranına karşı yanlış pozitiflerin oranını çizmektedir. Eğrinin sol üst köşeye yakın olması, modelin hem doğru pozitif oranını yüksek hem de yanlış pozitif oranını düşük tuttuğunu göstermektedir. Bu bağlamda, incelenen endeksler için oluşturulan Şekil 4'teki ROC eğrileri, modellerin iyi bir ayırt edicilik düzeyine sahip olduğunu ortaya koymaktadır.

AUC (Area Under the Curve) değeri ise ROC eğrisinin altındaki alanı ifade eder ve modelin sınıflar arasında ayrım yapabilme yeteneğinin genel bir göstergesidir. AUC

değeri 1'e ne kadar yakınsa, modelin o ölçüde başarılı olduğu kabul edilir. Çalışma kapsamında, AUC değerleri XUSIN için 0,9861; XBANK için 0,9848 ve XU100 için 0,9741 olarak elde edilmiştir. Bu yüksek AUC değerleri, rassal orman algoritmasının hem 'balon var' hem de 'balon yok' sınıflarını oldukça isabetli bir şekilde ayırt edebildiğini ve modelin genel sınıflandırma performansının güçlü olduğunu ortaya koymaktadır.

Sonuç olarak, eğitilen rassal orman sınıflandırıcı, test verisi üzerinde yapılan tahminlerle karşılaştırıldığında, BIST endeks fiyatlarındaki balon oluşumlarını yüksek doğrulukla tahmin edebilmiş ve sınıflandırma performansını hem pozitif hem negatif sınıflarda tutarlı bir şekilde sürdürmüştür.

Şekil 4: Rassal Orman Sınıflandırıcısının ROC Eğrileri



Kaynak: Yazar tarafından oluşturulmuştur.

Bir sonraki aşamada, endeks fiyat balonlarının oluşum olasılığını tahmin etmede makroekonomik ve finansal göstergelerin görece önem düzeyleri analiz edilmiştir. Söz konusu değişkenlerin, balon tahminlemesindeki açıklayıcılık düzeylerini yansıtan göreceli önemleri Tablo 6'da sunulmaktadır. Dikkat çekici olan husus, bu göstergelerin her üç endeks için ortak öngörücüler olarak öne çıkmasıdır. Tablo 6'da sunulan değerler, rassal orman algoritmasında kullanılan Gini safsızlığına dayalı değişken önem düzeylerini göstermektedir. Gini safsızlığı, her bir karar ağacındaki herhangi bir düğümde yanlış sınıflandırma olasılığını ifade eden bir ölçüttür ve modelin doğruluğuna katkı sağlayan değişkenleri öne çıkarır. Örneğin, XU100 endeksi için sepet kur değişkenine ait 0,191 değeri, bu değişkenin modelden çıkarılması durumunda Gini safsızlığının %19,1 oranında

azalacağını ve dolayısıyla modelin sınıflandırma başarısında kayda değer bir düşüş yaşanacağını göstermektedir. Bu bağlamda, önem düzeyleri, makroekonomik ve finansal değişkenlerin balon oluşumlarını tahmin etmede ne ölçüde etkili olduğunu ortaya koymaktadır.

Tablo 6: Değişkenlerin Önem Düzeyleri

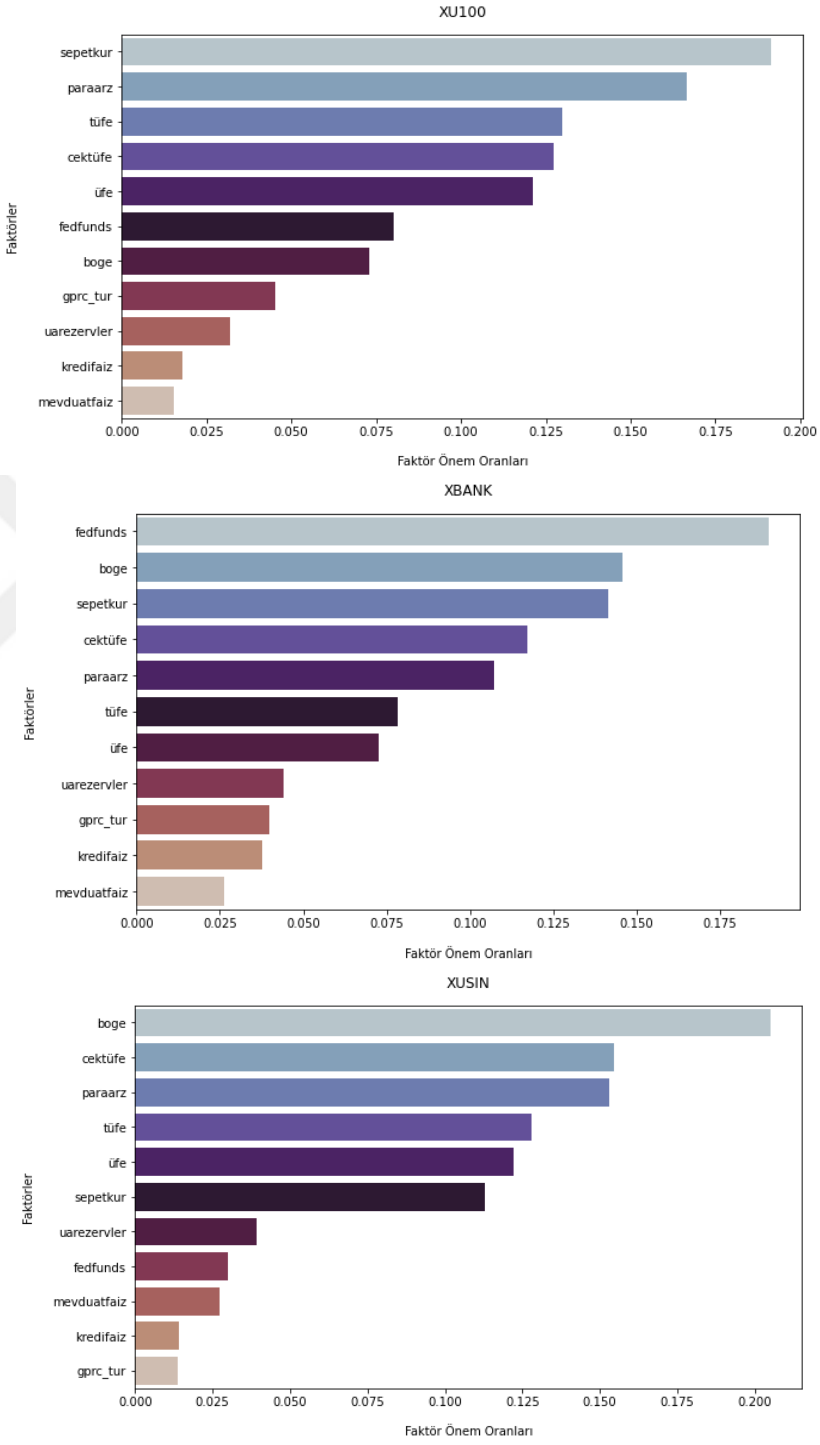
Değişkenler	XU100	XBANK	XUSIN
sepet kur	**0,191**	**0,142**	0,113
paraarz	**0,167**	0,107	**0,153**
tüfe	**0,13**	0,078	0,128
cektüfe	0,127	0,117	**0,154**
üfe	0,121	0,073	0,122
fedfunds	0,08	**0,189**	0,03
boge	0,073	**0,146**	**0,205**
gprc_tur	0,045	0,04	0,014
uarezervler	0,032	0,044	0,039
kredifaiz	0,018	0,038	0,014
mevduatfaiz	0,015	0,026	0,027

Kaynak: Yazar tarafından oluşturulmuştur.

Not : Tablo içerisindeki sayılar, Gini safsızlık ölçüsündeki ortalama azalmayı (%) temsil etmektedir. Kalın şekilde belirtilmiş sayılar, her bir endeks için en yüksek ağaç tahminleyicilerini göstermektedir.

Tablo 6 ve Şekil 5, endekslerde gözlemlenen balon riskini açıklamada en etkili makroekonomik değişkenleri sıralayarak rassal orman modelinin karar yapısına ilişkin önemli öngörüler sunmaktadır. Grafiksel analizden de görülebileceği üzere, özellikle sepet kur ve para arzı değişkenleri, XU100 endeksindeki balon oluşumlarını tahmin etmede en yüksek etkiye sahip öngörücüler arasında yer almaktadır. Bu bulgu, döviz kurlarının dalgalanmasının ve piyasadaki likidite koşullarının fiyat balonları üzerindeki belirleyici etkisini ortaya koymakta; dolayısıyla finansal istikrar açısından bu değişkenlerin kritik önemde olduğunu göstermektedir.

Şekil 5: Balon Tahminlemede Makroekonomik ve Finansal Faktörlerin Önem Oranları



Kaynak: Yazar tarafından oluşturulmuştur.

Enflasyon göstergeleri (TÜFE, Çekirdek TÜFE ve ÜFE) de önemli faktörler arasında yer aldığından fiyat artışlarının balon riskini artırabileceğini göstermektedir. FED Faiz Oranları ve mevduat, kredi faizleri gibi diğer makroekonomik göstergeler daha düşük ağırlığa sahip olduğu belirtilebilir ancak yine de piyasa dinamikleri üzerinde belirli bir etkiye sahiplerdir.

Grafikte açıkça görüldüğü üzere, FED Funds Rate (ABD Merkez Bankası'nın faiz oranı), XBANK endeksi üzerinde en büyük etkiye sahip faktördür. ABD'deki para politikasındaki değişiklikler, sermaye akışları ile Türkiye'deki bankacılık sektörünü doğrudan etkileyerek döviz kuru, faiz oranları ve kredi büyümesi gibi değişkenler üzerinde önemli etkiler yaratır. TÜFE ve çekirdek enflasyon gibi enflasyon göstergeleri ile kredi büyümesini temsil eden faktörler de XBANK endeksini etkileyen önemli değişkenler arasındadır. Yüksek enflasyon ve hızlı kredi büyümesi, finansal istikrarı tehdit ederek bankacılık sektörü üzerinde olumsuz etkiler yaratabilir.

FED faiz oranları gibi küresel faktörlerin yanı sıra, BOGE ve GPRC gibi yerel faktörlerin de XUSIN endeksi üzerindeki etkisi belirgindir. BOGE endeksi, Türkiye ekonomisinin gelecekteki performansı hakkında önemli ipuçları verirken, GPRC_TUR ise jeopolitik risklerin ekonomik aktivite üzerindeki etkilerini yansıtmaktadır. TÜFE ve ÜFE gibi enflasyon göstergelerinin de balon oluşumunda önemli bir rol oynadığı görülmektedir. Yüksek enflasyon, reel getirileri düşürerek yatırımcıları riskli varlıklara yöneltebilir ve böylece balon riskini artırabilir. Kredi faizi, mevduat faizi ve uluslararası rezervler gibi diğer değişkenlerin de balon oluşumunda belirli bir etkisi bulunmakla birlikte, bu etkilerin sepet kuru ve para arzı kadar güçlü olmadığı görülmektedir.

Rassal orman modeli tarafından elde edilen bulgular, BIST 100, BIST Banka ve BIST Sınai endekslerindeki fiyat balonlarının tahmininde görece daha etkili öngörücüler olarak sepet kur, para arzı, bileşik öncü göstergeler endeksi ve tüketici fiyat endeksi (TÜFE) değişkenlerini ön plana çıkarmaktadır. Başka bir ifadeyle, bu makroekonomik göstergeler, ilgili endekslerde balon oluşumlarını doğru şekilde sınıflandırmada daha yüksek katkı sunmaktadır. Öte yandan, Tablo 6'da sunulan sonuçlar, mevduat ve kredi faiz oranlarının balon tahminlemesinde daha sınırlı etkiye sahip olduğunu göstermekte ve bu bağlamda daha az belirleyici nitelikte olduğunu ortaya koymaktadır. Elde edilen bulgular

genel olarak değerlendirildiğinde, makroekonomik göstergelerin, finansal değişkenlere kıyasla fiyat balonlarının tahmininde daha güçlü ve açıklayıcı bir role sahip olduğu sonucuna ulaşılmaktadır.

1.3.4. Kısmi Bağımlılık Grafiği

Kısmi bağımlılık grafiği (Partial Dependence Plot, PDP), Friedman (2001) tarafından geliştirilen ve bir makine öğrenmesi modelinde belirli bir girdinin hedef değişken üzerindeki marjinal etkisini incelemek amacıyla kullanılan bir görselleştirme aracıdır. PDP'ler, özellikle rassal orman gibi kompleks ve yorumlanması güç "kara kutu" modellerde, bağımsız değişkenlerin tahmin üzerindeki etkisini görselleştirerek anlaşılmasını kolaylaştırmaktadır. Bu yöntem, bir değişkenin değeri sabit tutulurken model çıktısında meydana gelen ortalama değişimi göstererek, tahminciler ile hedef değişken arasındaki ilişkiyi görsel olarak temsil eder. PDP, bu yönüyle, modelin karar yapısını şeffaflaştırmakta ve kullanıcıya modelin hangi koşullarda nasıl tepki verdiğine ilişkin anlamlı içgörüler sağlamaktadır.

Fiyat balonlarını tahmin etmede değişkenlerin göreli önem düzeyleri tartışılmadan önce, söz konusu değişkenlerin endeks bazında balon oluşumu olasılığı üzerindeki etkilerini incelemek amacıyla, her bir endeks için en önemli üç tahmin edici değişkenin kısmi bağımlılık grafikleri (Partial Dependence Plots, PDP) analiz edilmiştir. Şekil 6, 7 ve 8, tahminleyici değişkenler ile endekslerdeki balon olasılığı arasındaki ilişkiyi görsel olarak sunmakta ve bu ilişkilerden elde edilen bulgular, balon oluşumlarına ilişkin erken uyarı mekanizmaları açısından önemli çıkarımlar sağlamaktadır.

XU100 endeksi için kısmi bağımlılık analizine dayalı bulgular Şekil 6'da sunulmuştur. Bu analiz kapsamında sepet kur, para arzı ve tüketici fiyat endeksi (TÜFE) değişkenlerinin endeks üzerindeki etkileri değerlendirilmiştir. Özellikle sepet kurda gözlenen artışın, 17,5 seviyesine kadar BIST 100 endeksinde fiyat balonu olasılığını anlamlı şekilde artırdığı tespit edilmiştir. Ancak bu eşik değerin aşılması sonrasında, sepet kurdaki ilave artışların balon oluşum olasılığı üzerinde ek bir etkisinin bulunmadığı görülmektedir. BIST 100 endeksindeki birçok büyük şirket, ihracat ağırlıklı çalışmaktadır.

Sepet kurun artması, yani TL'nin değer kaybetmesi, bu şirketlerin döviz cinsinden gelirlerinin TL karşılığını artırmakta ve böylece bu şirketlerin kârlılık oranları yükselmektedir. Özellikle otomotiv, demir-çelik, savunma sanayi ve tekstil gibi ihracata dayalı sektörler sepet kurdaki artıştan olumlu etkilenebilir ve bu durum, endeks üzerinde yukarı yönlü bir baskı yaratabilir. Buna karşılık, üretiminde yüksek oranda ithal girdi kullanan sektörler açısından sepet kur artışı maliyet kanalı üzerinden olumsuz etki yaratmakta ve endeks üzerinde aşağı yönlü bir baskı oluşmasına neden olabilmektedir. Dolayısıyla, sepet kurun 17,5 seviyesinden sonraki artışı, balon olasılığında belirgin bir değişim yaratmamakta, bu seviyede bir eşik etkisinin varlığına işaret etmektedir.

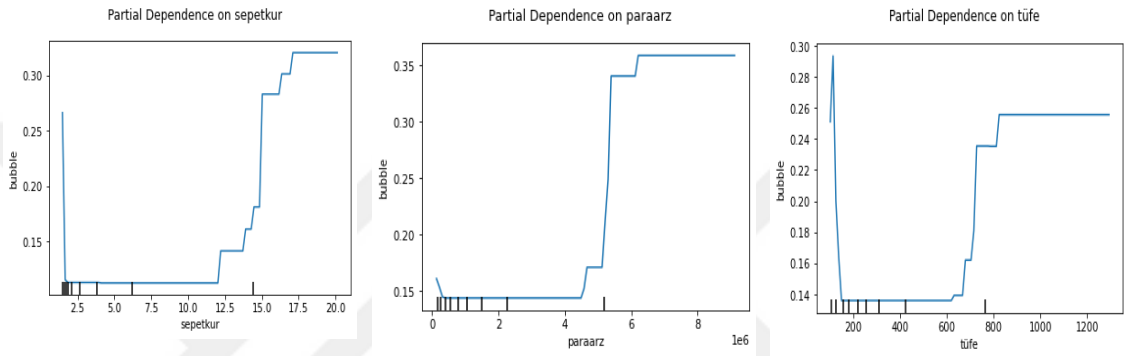
Para arzı ve TÜFE grafikleri incelendiğinde sepet kur ile benzer bağımlılık gösterdikleri görülebilecektir. Yüksek sepet kur enflasyonist baskıları artırarak şirketlerin maliyet yapısını olumsuz etkileyebileceğinden TÜFE ve para arzının belli bir seviyeden sonra artması balon oluşum olasılığına önemli derecede etki etmektedir. Şekil 8'de yer alan XUSIN ve para arzı için balon olasılığı grafiğinde açıkça görülmektedir ki para arzındaki artışlar sanayi sektöründeki hisse senedi fiyatlarını pozitif yönde etkileyebileceğinden bu durum yatırımcılar için önemli bir gösterge oluşturmaktadır.

Şekil 7'de yer alan XBANK endeks fiyatındaki balon oluşum olasılığı ve sepet kur arasındaki ilişki de XU100 endeksine benzer şekilde ifade edilebilmektedir. Sepet kur, enflasyon, faiz oranları ve diğer makroekonomik göstergelerle etkileşim halindedir. Özellikle döviz kurundaki volatilite, bankacılık sektörünün finansal sağlığı üzerinde doğrudan ve dolaylı etkiler yaratabilmektedir. Yüksek döviz kuru, bankaların döviz pozisyonlarını bozarak kredi riskini artırabilir ve karlılıklarını olumsuz etkileyebilir. Ayrıca, kur dalgalanmaları, dış ticaret dengesi üzerindeki etkisiyle de bankacılık sektörünün faaliyetlerini dolaylı olarak şekillendirmektedir (Aka, 2020).

Şekil 7'de yer alan grafiğin başlangıcında, FED faiz oranı 2'nin altındayken balon olasılığı çok düşük seviyede kalmaktadır. Bu durum, faiz oranlarının düşük olduğu dönemlerde XBANK endeksinde balon oluşma olasılığının çok düşük olduğunu göstermektedir. FED faiz oranı 2'nin üzerine çıktığında balon olasılığı hızla artmakta ve 4 civarına geldiğinde yaklaşık 0.27 seviyesine ulaşmaktadır. Bu, faiz oranlarının belirli bir seviyeye kadar arttıkça balon oluşma ihtimalinin yükseldiğini göstermektedir. FED'in

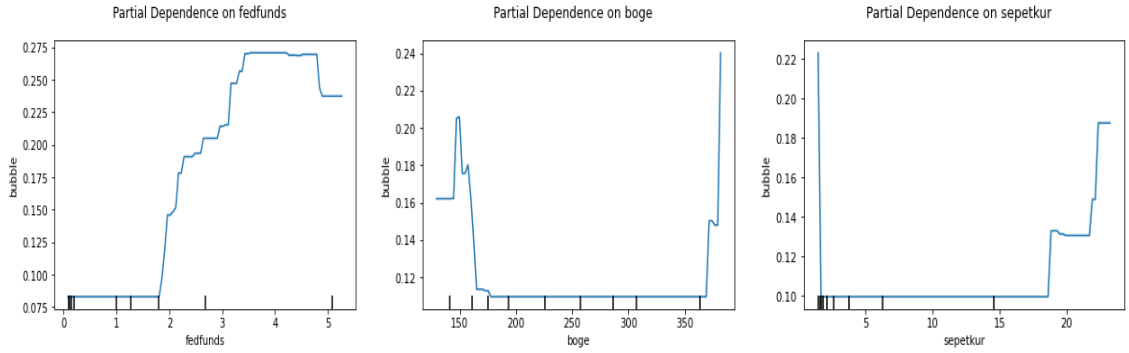
politika faiz oranı yüzde 4,5'u aştığında XBANK endeks fiyatında balon oluşma olasılığının azaldığı ve bu nedenle parasal sıkılaşma ve yükselen faiz oranlarının banka hisselerine etkisinin dikkate değer olduğu görülmektedir.

Şekil 6: XU100 için Kısmi Bağımlılık Grafikleri



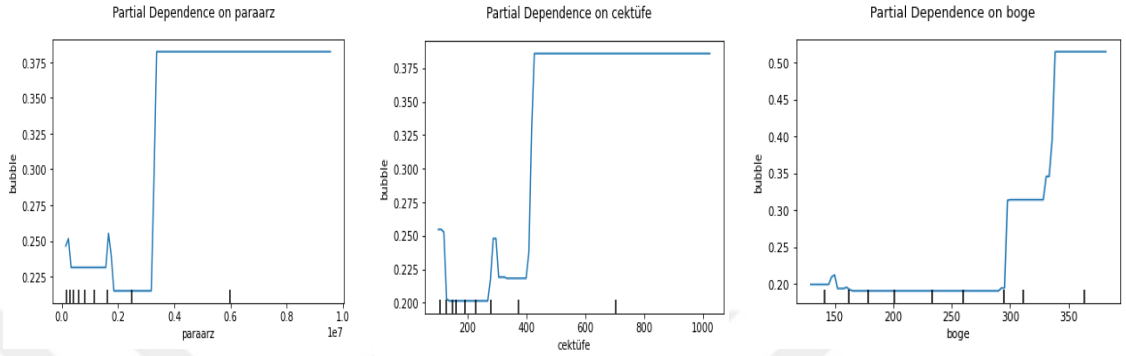
Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 7: XBANK için Kısmi Bağımlılık Grafikleri



Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 8: XUSIN için Kısmi Bağımlılık Grafikleri



Kaynak: Yazar tarafından oluşturulmuştur.

Not: Dikey eksen, olasılık oranının logaritmasını göstermektedir. Olasılık oranı, "p /(1-p)" olarak ölçülür ve burada p, balon olasılığını temsil etmektedir. Yatay eksen, tahmin edici değerlerin seviyelerindeki değerlerini göstermektedir.

Şekil 7 ve 8'de BOGE'de 300-350 seviyelerinden sonra meydana gelen artışın XBANK ve XUSIN endekslerindeki balon olasılığını arttırdığı görülmektedir. Araştırmalar, bileşik öncü göstergelerin XBANK üzerindeki etkisinin istatistiksel olarak anlamlı olduğunu ortaya koymuştur. BOGE sanayi sektöründeki şirketlerin geleceğe yönelik beklentilerini yansıttığı için, yatırımcıların bu göstergeleri dikkate alarak stratejilerini belirlemeleri önerilmektedir. Özellikle sanayi üretimindeki değişimlerin ve piyasa beklentilerinin, XUSIN üzerindeki etkileri yatırım kararlarını etkileyebilmektedir (Ünal, 2021).

Genel olarak değerlendirildiğinde, makroekonomik faktörler endeks bazlı fiyat balonlarının öngörülmesinde belirleyici bir rol üstlenmektedir. Bununla birlikte, analiz kapsamında incelenen göstergeler arasında mevduat ve kredi faiz oranlarının, balon oluşumuna etki etme gücünün görece olarak daha düşük kaldığı gözlemlenmiştir. Tüm endeksler için yapılan değerlendirmelerde, bu iki finansal değişkenin, fiyat balonlarını tahmin etme konusunda diğer makroekonomik göstergelere kıyasla daha sınırlı bir açıklayıcılık düzeyine sahip olduğu tespit edilmiştir. Bu bulgu, faiz oranlarının endeks

fiyatlarındaki spekülatif dalgalanmaları açıklama kapasitesinin düşük olduğunu ve balon oluşumlarını öngörmede ikincil düzeyde kaldığını ortaya koymaktadır.

1.4. SONUÇ

Borsa endeksleri ve bu endekslerdeki fiyat hareketleri, sermaye piyasalarının işleyişinde kritik bir rol oynayan temel finansal göstergeler arasında yer almakta ve bir ülkenin finansal gelişmişlik düzeyini yansıtan başlıca belirleyicilerden biri olarak kabul edilmektedir. Varlık fiyatlarının, ekonomideki kaynak tahsisini etkilediği dikkate alındığında (Brunnermeier, 2016; Stiglitz, 1990), bu fiyatların hangi koşullarda ve ne ölçüde temel değerlerinden sapma gösterdiğini anlamak, hem iktisadi analiz hem de politika yapımı açısından büyük önem arz etmektedir. Bu tür bir anlayış, aynı zamanda yatırımcılar, düzenleyici kurumlar ve politika yapıcılar için erken uyarı sistemlerinin (EWS) geliştirilmesine de zemin hazırlayarak daha bilinçli ve proaktif kararlar alınmasını mümkün kılabilir. Finansal gelişmişliğin yüksek olduğu ekonomilerde, istikrarlı bir makroekonomik ortam sağlandığında piyasa volatilitesinin azalacağı ve bunun da sistemik riski düşüreceği öngörülmektedir.

Finansal balonlar, varlık fiyatlarında temel değerlerden sapma biçiminde gelişen süreklilik arz eden ve sistematik fiyat artışlarıyla karakterize edilen spekülatif süreçler sonucunda ortaya çıkmakta ve bu durum, ciddi finansal krizlere zemin hazırlayabilmektedir. Varlık piyasalarında görülen spekülatif hareketler, fiyatlarda keskin dalgalanmalara yol açarak hem finansal istikrarı tehdit edebilmekte hem de yatırımcı davranışlarını irrasyonel yönlere sevk edebilmektedir. Bu bağlamda, çalışmada Borsa İstanbul'da işlem gören BIST 100, BIST Banka ve BIST Sınai endeksleri 2002–2024 dönemi aylık kapanış fiyatları üzerinden analiz edilmiştir. Finansal balon oluşumlarının belirlenmesinde, Phillips, Shi ve Yu (2015) tarafından geliştirilen özyinelemeli Sağ Kuyruklu Genelleştirilmiş Supremum Artırılmış Dickey-Fuller (GSADF) testi kullanılmıştır.

Elde edilen bulgular, sınanan temel hipotezlerin reddedildiğini ve ilgili tüm endekslerde dönemsel olarak finansal balon oluşumlarının yaşandığını ortaya

koymaktadır. Tespit edilen bu balonların, büyük ölçüde yabancı sermaye hareketleri, Türkiye ve ABD merkez bankalarının politika kararları gibi dışsal makro-finansal faktörlerle ilişkili olduğu değerlendirilmektedir. Bu sonuçlar, Borsa İstanbul'da etkin piyasa varsayımının tam anlamıyla geçerli olmadığını ve yatırımcıların rasyonel beklentilerden saparak spekülatif davranış kalıpları ve sürü psikolojisi etkisiyle hareket ettiklerini göstermektedir. GSADF testine dayalı analiz sonuçları, her bir endeksin farklı zaman dilimlerinde balon oluşumlarına maruz kaldığını ve bu oluşumların piyasaya özgü dinamiklerle şekillendiğini ortaya koymaktadır.

Makine öğrenmesi algoritmalarının başarısı, yalnızca kullanılan özniteliklerin sayısı ve niteliğine değil, aynı zamanda bu özniteliklerin hedef değişkenle olan ilişkisine ve temsil gücüne de bağlıdır. Yüksek temsil gücüne sahip öznitelikler bile, uygun bir kombinasyon oluşturulmadığı takdirde, makine öğrenme algoritmalarının başarısını olumsuz etkileyebilir. Bu çalışmanın ikinci aşamasında, finansal balon oluşumlarının gerçek zamanlı tahmini amacıyla rassal orman algoritması kullanılmıştır. Yapılan analizler, fiyat balonlarının oluşumunun endeks bazında farklılık gösterebildiğini ve bu durumun endekse özgü yapısal faktörlerden kaynaklandığını ortaya koymaktadır. Ayrıca, her bir endeks için balon oluşumunu etkileyen değişkenlerin eşik değerleri belirlenmiş olup bu eşikler finansal balonların önceden tespiti için erken uyarı göstergeleri geliştirilmesinde kullanılabilecek niteliktedir.

Bu çalışma, finansal ve makroekonomik değişkenler ile fiyat balonları arasındaki ilişkiyi makine öğrenmesi modelleri aracılığıyla incelemesi bakımından literatürde öncü bir girişim niteliği taşımaktadır. Makine öğrenmesi algoritmalarının temel avantajı, değişkenler arasındaki ilişkiyi önceden belirlenmiş bir fonksiyonel forma ihtiyaç duymaksızın öğrenebilme kapasitesine sahip olmaları ve klasik istatistiksel modellerde olduğu gibi katı dağılım varsayımlarına dayanmamalarıdır. Aynı zamanda, bu algoritmalar modelin örneklem dışı geçerliliğini test etme olanağı sunarak, tahmin performansının genellenebilirliğini değerlendirmeye imkân tanımaktadır. Finansal piyasalar ve bu piyasalara ilişkin temel endeks göstergeleri dikkate alındığında, bu tür veri odaklı EWS, yatırımcıların portföylerini daha etkin biçimde yeniden tahsis etmelerine katkı sağlayabilir ve sistemik risklerin yönetiminde önemli bir araç işlevi görebilir.

Bu çalışma doğrultusunda gelecekteki çalışmalarda söz konusu endeksleri veya XU100 ve XBANK gibi diğer endekslerdeki balon oluşumlarının da benzer bir şekilde incelenmesi, sonuçların genel geçerliliğini artıracaktır. Bu bağlamda makine öğrenmesi alanındaki gelişmeler doğrultusunda, farklı algoritmaların kullanılması ile sonuçların doğrulanması önemlidir. Balon oluşumları ve makroekonomik değişkenler arasındaki non-lineer ilişkilerin incelenmesi, balon oluşumunun daha iyi anlaşılmasına katkı sağlayabilir. Sonuç olarak bu çalışma borsa endeksindeki balon oluşumunu anlamak için önemli bir adım teşkil etmektedir. Ancak, balon riskini tamamen ortadan kaldırmak mümkün olmamakla birlikte, uygun politikalar ve düzenlemeler ile bu risk azaltılabilir.

Bu çalışmada elde edilen bulgular, potansiyel balonlar konusunda farkındalık oluşturmak üzere EWS geliştirmek amacıyla kullanılabilir. Gelecekte bu konuda yapılacak çalışmalar için, EWS'lerin farklı veri kaynakları ve algoritmalarla entegrasyonu, farklı piyasa koşullarına ve endekslere uyarlanabilirliği üzerine odaklanılabilir. Çalışmada kullanılan rassal orman algoritması, balon oluşumunu tahmin etmede umut vaadetse de derin öğrenme modelleri gibi diğer makine öğrenmesi tekniklerinin de araştırılması ve karşılaştırılması önemlidir. Balon dinamikleri ve etkileşimlerini daha ayrıntılı analiz etmek için zaman serisi analizi ve diğer ekonometrik teknikler kullanılabilir.

İKİNCİ BÖLÜM
RASSAL ORMAN ALGORİTMASINA DAYALI OLARAK TÜRKİYE'DE FİNANSAL KRİZLERİN TAHMİNLENMESİ

Finansal krizler, literatürde farklı kavramsal çerçevelerden ele alınmaktadır. Mishkin (1996), krizleri finansal piyasaların etkin kaynak tahsisini sekteye 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; Ozcelebi 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.

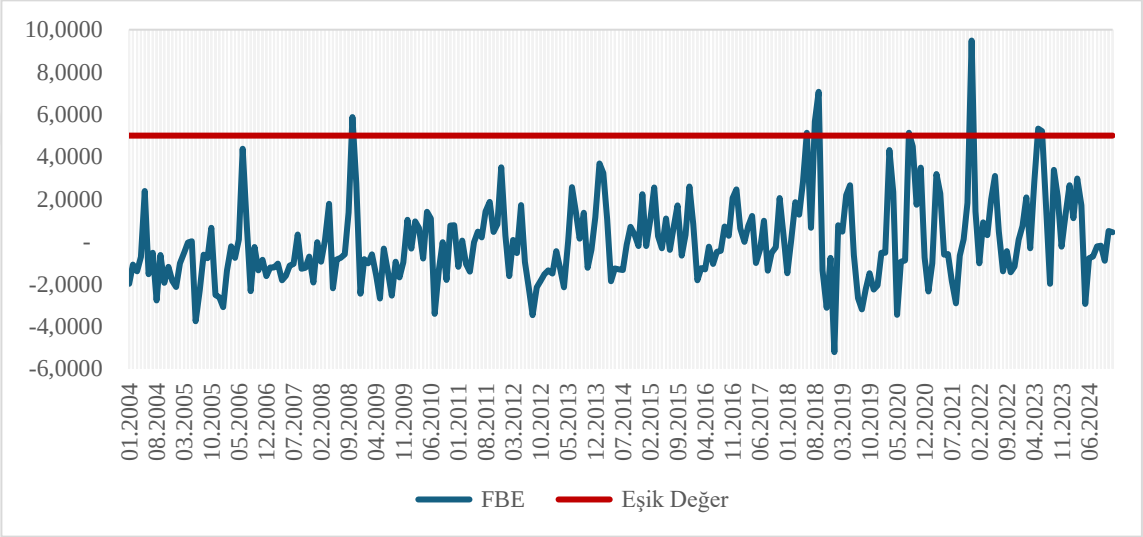
Ancak, finansal sistemlerin ve kriz dinamiklerinin güncel faktörlere bağlı artan karmaşıklığı, geleneksel ekonometrik yöntemlerin öngörü kapasitesindeki sınırlılıkları ortaya koymuştur. Finansal kriz öngörüsü için doğrusal olmayan yapıları çözümleyebilen ve veriye dayalı öğrenme sağlayan makine öğrenmesi tekniklerinin gelişimi bu alana yeni bir boyut kazandırmıştır (Yildirim vd., 2011). Bu teknikler, özellikle politika yapıcılar için kritik önem taşıyan 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 FBE oluşturmayı ve bu endeksi rassal orman makine öğrenmesi algoritması ile modelleyerek finansal krizleri tahminlemeyi amaçlamaktadır. Şekil 9'da 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 9: Türkiye'de Kriz Dönemleri



Kaynak: Yazar tarafından oluşturulmuştur.

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 göreli önem düzeyleri belirlenmektedir.

2.1. LİTERATÜR TARAMASI

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, 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) ise ulusal paranın nominal olarak %25'ten fazla değer kaybetmesi ya da bir sene önceki değer kaybından en az %10 daha fazla değer kaybı buhran tanımı olarak kabul etmiş ve 1971-1992 yıllarına ait 105 gelişmekte olan ülke verisiyle çalışmıştır. Bulgular, doğrudan yabancı yatırımlarda azalma, rezervlerde düşüş, kredi hacminde artış, aşırı değerli döviz kuru ve gelişmiş ülkelerdeki faizlerde yükselişin anlamlı öncü göstergeler olduğunu ortaya koymuştur. Kaminsky vd. (1998), döviz kurlarındaki aylık yüzde değişim ve brüt uluslararası rezervlerdeki yüzde değişim ile oluşturulan Finansal Baskı Endeksi'nin eşik değerini aşmasını kriz olarak ele almış ve 1970-1995 döneminde 15 gelişmekte olan ülkeye ait verileri incelemiştir. Araştırma sonucunda, reel döviz kurunda artış, ithalatta yükseliş, rezervler ve borsa endeksindeki düşüş, para arzının uluslararası rezervlere oranındaki artış ve çıktı seviyesindeki azalmanın krizin öncü sinyallerini verdiği sonucuna ulaşılmıştır. Benzer şekilde Edison (2003), döviz kurlarındaki yüzde değişim ve uluslararası rezervlerdeki yüzde değişim ile oluşturulan Finansal Baskı Endeksi'nin eşik değerini aşmasını kriz tanımı olarak kullanmış ve 1970-1995 yılları arasındaki 20 ülkeye ait verileri analiz etmiştir. Çalışma, döviz kurlarındaki yükseliş, M2'nin rezervlere oranındaki artış, döviz rezervlerindeki azalma ve hisse senedi fiyatlarındaki ani düşüşlerin anlamlı öncü göstergeler olduğunu göstermiştir. Türkiye özelinde Kaya ve Yılmaz (2007), Finansal Baskı Endeksi'nin eşik

değerini aşmasını kriz olarak tanımlayarak 2003-2005 dönemi Türkiye verilerini incelemiştir. Bulgular, bütçe dengesindeki bozulma, M2'nin kısa vadeli dış borçlara oranının, dış ticaret hadlerinin GSMH'ye oranları ve reel döviz kurunun değerlenmesinin krizin öncü göstergeleri olduğunu ortaya koymuştur. 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), ulusal paranın Amerikan doları ya da bir denge döviz karşısında yıllık en az %15 değer kaybetmesini kriz tanımı olarak benimsemiş ve 1800-2006 yılları arasındaki 70 ülke verisiyle bir çalışma gerçekleştirmiştir. Enflasyon, kamu ve özel sektör borçlarındaki artışın kriz olasılığını arttırdığı sonucuna ulaşılmıştır. 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), Finansal Baskı Endeksi'nin eşik değerini aşmasını kriz olarak tanımlayarak 1990-2010 döneminde Türkiye, Arjantin, Tayland ve İngiltere verilerini analiz etmiştir. Araştırma, reel faiz oranı, reel döviz kurunun trendden sapması, para piyasası baskı endeksi ve yurtiçi kredilerin endüstriyel üretime oranındaki artışın krizin anlamlı öncü göstergeleri olduğunu ortaya koymuştur. 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. Ozcelebi (2020) tarafından yapılan çalışmada, pozitif ve negatif finansal stres endeksi şoklarının, gelişmekte olan ülkelerin finansal baskı endeksini düşük, orta ve yüksek baskı rejimlerinde farklı şekillerde etkileyip etkilemediği ve finansal stres endeksindeki değişimlerin finansal baskı endeksi üzerinde önemli bir asimetrik etkiye sahip olup olmadığı incelenmiştir. Ayrıca, finansal stres endeksindeki bu değişikliklerin finansal baskı endeksinde dengeleyici mi yoksa dengesizleştirici mi etkilere yol açtığı da araştırılmıştır. 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, belirli bir dönemde tanımlanmış muhtemel krizleri öngörmek için geliştirilen ve potansiyel öncü göstergelerin belirlenmesini içeren düzeneklerdir. Küresel kriz dönemlerinde ülkelerin kırılganlıklarını tespit ederek politika yapıcıların 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, DVM ve sinir ağları 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 (DVM, rassal orman, CART, naif bayes, lojistik regresyon) 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, Türkiye için 2004 Ocak-2024 Aralık dönemini kapsayan bir FBE oluşturmayı ve bu endeksi rassal orman algoritmasıyla bütünleştirerek finansal krizlerin öncü göstergelerini EWS olarak kullanmayı amaçlamaktadır. Çalışmanın özgün katkıları arasında dengesiz veri kümeleri için uygun veri önişleme 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.

2.2. VERİ SETİ

Bu çalışma, ilk aşamada Türkiye için Ocak 2004 – Aralık 2024 dönemine ait aylık verilerle güvenilir bir kriz tanımı temelinde FBE oluşturarak 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 7'de özetlenerek sunulmuştur.

Tablo 7: 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

Kaynak: Yazar tarafından oluşturulmuştur.

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.

2.3. YÖNTEM

2.3.1. 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 eşitlik 12'de yer alan formül ile hesaplanabilmektedir (Ural ve Balaylar, 2007).

$$FBE = \frac{\left(\frac{\Delta K}{K}\right) - \mu_K}{\sigma_K} + \frac{\left(\frac{\Delta F}{F}\right) - \mu_F}{\sigma_F} - \frac{\left(\frac{\Delta R}{R}\right) - \mu_R}{\sigma_R} \qquad (12)$$

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.

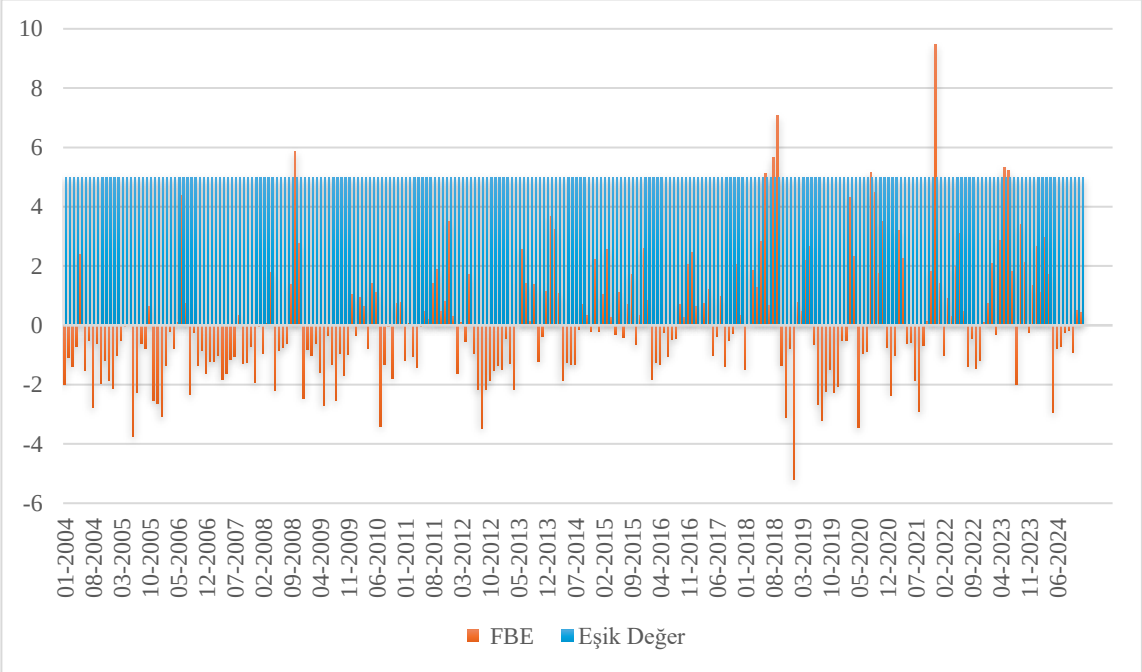
Çalışmanın bu bölümünde, 2004 yılından itibaren Türkiye'deki finansal kriz dönemleri, eşitlik 1'deki FBE oluşturularak ve aşağıda sunulan eşik değer bilgisi dikkate alınarak tespit edilmiştir.

$$FBE \geq (\mu + 2.5\sigma) \rightarrow \text{Kriz Durumu}$$

$$FBE \leq (\mu + 2.5\sigma) \rightarrow \text{Kriz Olmama Durumu}$$

Şekil 10'da 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 aştığında kriz durumu (1), aşmadığı dönemlerde ise kriz olmayan durum (0) olarak tanımlanmıştır. FBE sonuçlarına dayanılarak tespit edilen kriz dönemleri Tablo 8'de sunulmaktadır.

Şekil 10: 2004-2024 Dönemi için FBE ile Belirlenen Finansal Krizler



Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 8: 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

Kaynak: Yazar tarafından oluşturulmuştur.

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.

2.3.2. 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 rassallik 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 örneklemine 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.

$$m = \sqrt{p} \qquad (13)$$

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.

$$\hat{C}_{rf}^{B}(x) = \text{çoğunluk oylaması}\left\{\hat{C}_b(x)\right\}_1^B \quad (14)$$

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

$$E_{OOB} = \frac{1}{N}\sum_{i=1}^{N} I\left(Y_i \neq \widehat{C}_{rf}^{B}(x)\right) \quad (15)$$

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 $\widetilde{OOB}_t^j$ ile gösterilir. Daha sonra $\widetilde{OOB}_t^j$ değerinin hatası hesaplanır ve bu $Err\widetilde{OOB}_t^j$ ile gösterilir. Bu işlemler tüm bootstrap örneklemleri için tekrar edilir. X^j değişkeninin önemi $VI(X^j)$ ile gösterilir ve aşağıdaki gibi hesaplanır.

$$VI(X^j) = \frac{1}{ntree}\sum\left(Err\widetilde{OOB}_t^j - Err_{OOB_t}\right) \quad (16)$$

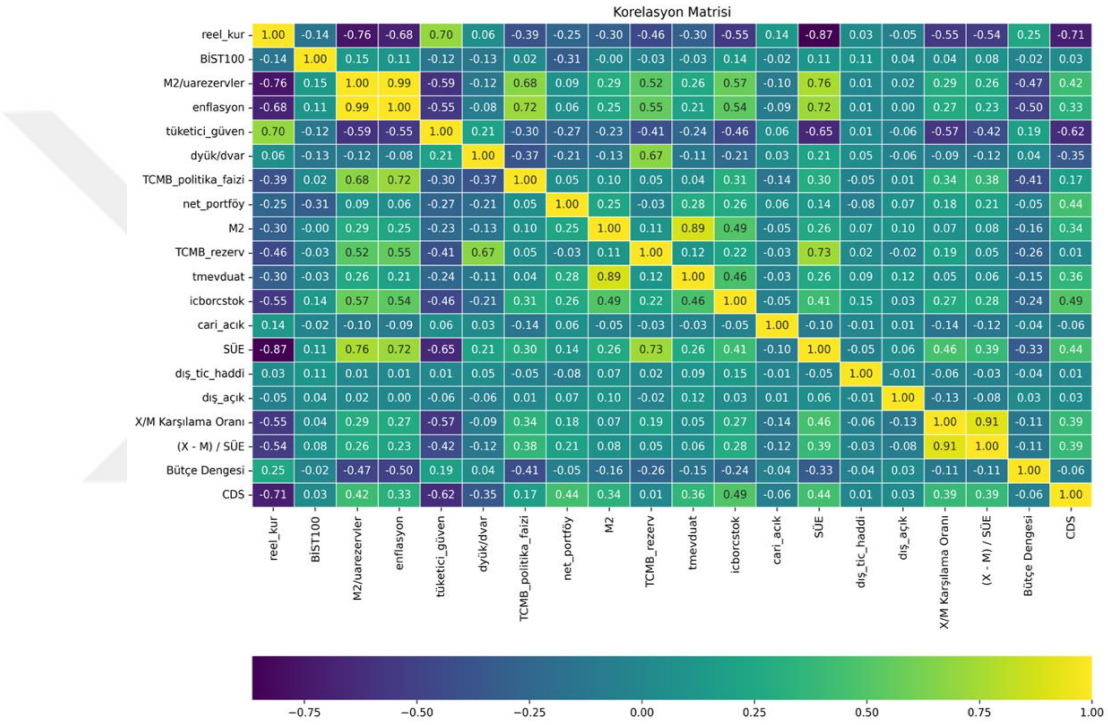
Bir değişkenin rassal permütasyonlarından kaynaklanan hata miktarındaki artış ne kadar yüksek ise ilgili değişkenin modeldeki önemi de o kadar fazladır. Aksine, permütasyonların hata üzerinde minimal veya sıfır etkisi olması durumunda, söz konusu değişkenin model için önemsiz olduğu değerlendirilir (Bayram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

2.4. ANALİZ VE BULGULAR

Makine öğrenimi uygulamasına başlamadan önce, Türkiye'deki finansal kriz dönemlerini tahmin etmek için kullanılan öncü göstergeler arasındaki korelasyon değerleri incelenmiştir. Şekil 11'de 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 11: Öncü Göstergeler Arasındaki Korelasyon Değerleri



Kaynak: Yazar tarafından oluşturulmuştur.

2.4.1. 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 9'da yer almaktadır. Bu çalışma, makine öğrenimi model seçimi ve optimizasyon süreçlerine sistematik bir yaklaşım sunmayı amaçlamaktadır.

Tablo 9: LazyPredict Rassal Orman Tahmin Sonuçları

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

Kaynak: Yazar tarafından oluşturulmuştur.

2.4.2. 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 10, 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 10: Model İyileştirme Sonrası En İyi Parametreler

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

Kaynak: Yazar tarafından oluşturulmuştur.

Makine öğrenmesinde değerlendirme ölçütleri, modellerin başarısını anlamak ve kıyaslamak için önemli bir rol oynamaktadır. Bu çalışmada, rassal orman algoritmasının sınıflandırma performansını değerlendirmek amacıyla doğruluk oranı, kesinlik (precision), duyarlılık (recall), özgüllük (specificity), F1 skoru ve AUC (Area Under the Curve) gibi çeşitli performans metriklerinden yararlanılmıştır. 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 11,

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 11: Rassal Orman Modeli Tahmin Performans Sonuçları

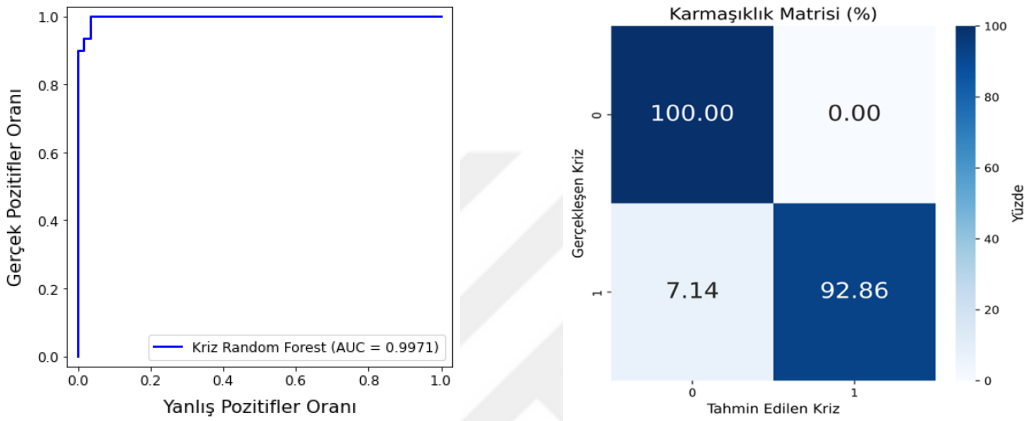
Ölçüt	Değer
Doğruluk	0.9216
Kesinlik	0.9310
Duyarlılık	0.9000
Özgüllük	1.0000
F1 Puanı	0.9153
AUC	0.9971

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 12, 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.

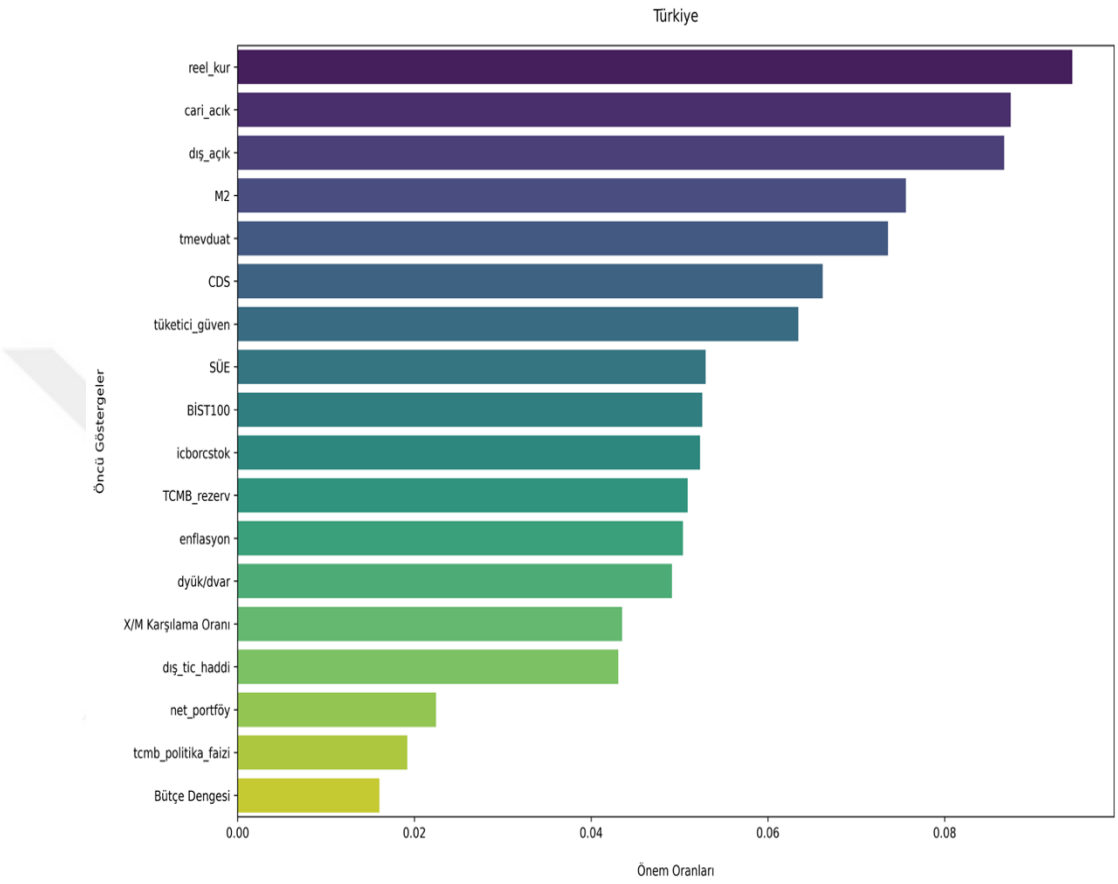
Şekil 12: Kriz Tahminlemesinde ROC eğrisi ve Karmaşıklık Matrisi



Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 13'te, Türkiye'deki finansal kriz dönemlerini tahminlemede kullanılan rassal orman algoritmasındaki öncü göstergelerin önem düzeyleri görselleştirilmektedir. Bu göstergelerin önem düzeyleri, kriz tahmini açısından hangi göstergenin daha belirleyici olduğunu ortaya koymaktadır. Tablo 12'de ise bu göstergelerin aynı önem düzeyleri sayısal değerleriyle sunulmaktadır. Bu değerler kriz riskinin belirlenmesinde en etkili olan göstergeleri sıralayarak modelin karar alma sürecine ilişkin önemli bilgiler sunmaktadır. Modelin kriz sınıflandırması yaparken hangi değişkenlere daha fazla ağırlık verdiğini gösteren bu önem sıralaması, makroekonomik kırılganlıkların kaynakları hakkında değerli bilgiler içermektedir.

Şekil 13: Potansiyel Kriz Tahmincileri Önem Oranları Bar Grafiği



Kaynak: Yazar tarafından oluşturulmuştur.

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 gerekecek 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.

Tablo 12: Potansiyel Kriz Tahmincileri 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

Kaynak: Yazar tarafından oluşturulmuştur.

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 atfettiği 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 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 sıkıntı düzeyindeki artış, genel ekonomik görünümde belirsizliğin yükselmesine ve varlık fiyatlarında oynaklığın artmasına neden olabilmektedir. Bu bağlamda, döviz piyasası hem finansal baskıdan etkilenen temel piyasalardan biri hem de finansal sıkıntının önemli kaynaklarından biridir. Ayrıca, kamu kesiminin yüksek düzeyde borçlanması da finansal sıkıntıyı tetikleyen unsurlar arasında yer almaktadır. Aynı zamanda Türkiye'nin kredi risk priminin 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 spekülatif 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 göreli 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.

2.4.3. Kısmi Bağımlılık Grafikleri

Şekil 14'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 vurgulanmaktadır (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 beklenmektedir. İncelenen 2004-2024 döneminde, TL'nin reel olarak değerli olduğu zaman dilimleri, *eş zamanlı* olarak güçlü sermaye girişleri, yüksek büyüme oranları, düşük ülke risk primi veya genel olarak olumlu bir küresel konjonktür gibi *başka faktörlerle* örtüşmüş 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

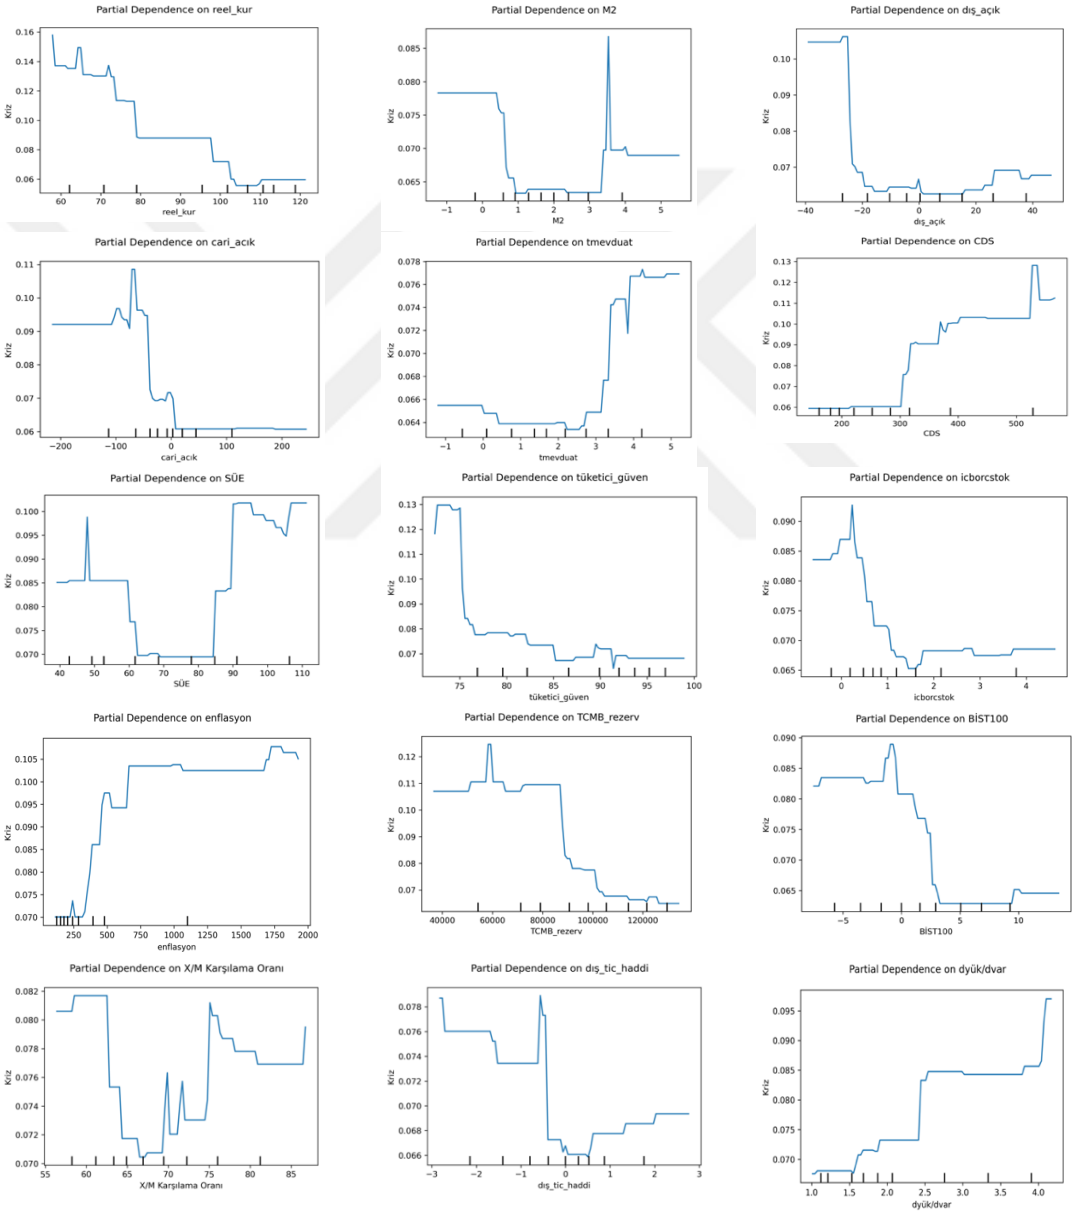
faktörlerle açıklanabilmektedir. Bu nedenle, sonucun yorumlanmasında dikkatli olunmalı ve reel kurdaki *aşırı değerlenmenin* orta-uzun vadede finansal kırılganlıkları artırabileceği yönündeki temel iktisadi prensip göz ardı edilmemelidir.

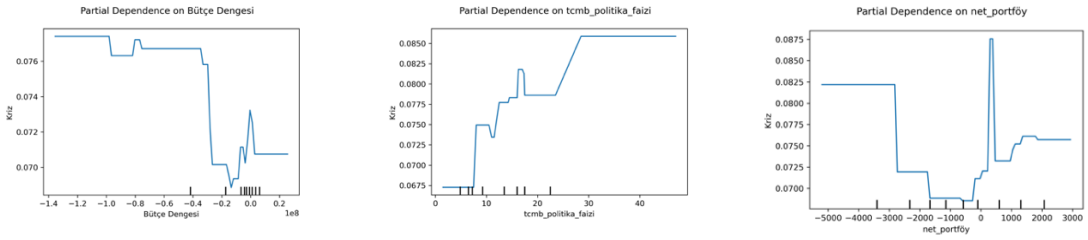
Kriz olasılığı ile negatif ilişkisi olan bir diğer öncü gösterge TCMB rezervleridir. Rezervler azaldıkça (özellikle 60 milyar USD altı) risk artmakta, yeterli rezerv seviyeleri (örn. 90-100 milyar USD üzeri) ise en düşük riskle ilişkilidir. Bu, rezervlerin dış şoklara karşı tampon rolünü vurgulayan literatürle (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 yansıtabilmektedir. 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 açıklanabilmektedir. 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 gösterebilmektedir. 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 açıklayabilmektedir. 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 değerlendirilebilmektedir.

Şekil 14: Öncü Göstergeler Kısmi Bağımlılık Grafikleri





Kaynak: Yazar tarafından oluşturulmuştur.

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 arttırır ve bu sonuç ülkenin dış finansman koşullarındaki değişimlere veya şoklara karşı daha hassas hale geldiğini gösteren literatürle (Lane ve Milesi-Ferretti, 2007) uyumludur.

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 (Aydin, 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.

2.5. 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, EWS'nin kalibrasyonu ve etkinliği açısından değerli bilgiler sağlamaktadır.

Bulgular ışığında, Türkiye'nin gelecekteki olası finansal, ekonomik şoklara karşı direncini artırmak amacıyla yeni bir ekonomik paradigmaya ve proaktif politika setine ihtiyaç duyduğu açıktır. Reel döviz kurunun dış ticaret dengesi ve dolayısıyla büyüme, istihdam, enflasyon gibi temel makroekonomik değişkenler üzerindeki kritik etkisi göz önüne alındığında, politika yapıcıların 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 modern ekonometrik veya makine öğrenmesi yöntemleriyle derinlemesine analiz edilmesi, gelişmekte olan ülke ekonomilerindeki kriz oluşum mekanizmalarının daha iyi kavranmasına önemli katkılarda bulunabilir.

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.

ÜÇÜNCÜ BÖLÜM
BİR MAKİNE ÖĞRENİMİ UYGULAMASI: G7 ÜLKELERİNDE FİNANSAL KRİZ TAHMİNLEME

Finansal krizler, ekonomi ve sosyal sistemler üzerinde önemli maliyetlere neden olmaktadır (Hoggarth vd., 2002; Laeven ve Valencia, 2018). Bu bağlamda, finansal krizlere işaret eden uyarı sinyallerinin zamanında tespiti politika yapıcılar açısından kritik bir öneme sahiptir. Erken teşhis konjonktür karşıtı makro ihtiyati politikaların etkin bir şekilde uygulanmasına olanak tanımakta ve böylece artan riskler karşısında finansal krizlerin ortaya çıkma olasılığı ve etkileri azaltılabilmektedir (Giese vd., 2013; Akinci ve Olmstead-Rumsey, 2018). Bununla birlikte güvenilir bir erken uyarı gösterge seti oluşturmak çeşitli zorluklar içermektedir. İlk olarak geçmişte gözlemlenen finansal krizlerin sayısının sınırlı olması, sağlam ekonometrik modelleme çalışmalarını güçleştirmektedir. İkinci olarak kriz sinyalleri genellikle müdahale için elverişli zaman dilimi aşıldıktan sonra belirginleşmektedir. Üçüncü olarak karmaşık erken uyarı modellerini makro ihtiyati otoritelerin zamanında müdahalesine rehberlik edecek, basit ve şeffaf göstergelere indirgemek zor olabilmektedir. Son olarak ekonomik ve finansal sistemler doğası gereği öngörülemezliğe ve belirsizliğe tabidir. Bu durum, Covid-19 salgınının ekonomik etkilerinde gözlemlendiği gibi bazı olayların önceden tahmin edilmesinin neredeyse imkânsız olduğu anlamına gelmektedir (Aikman vd., 2021). Ancak, altta yatan kırılganlıkların tespit edilmesi, bu tür olağanüstü durumlarda dahi faydalı olabilmektedir.

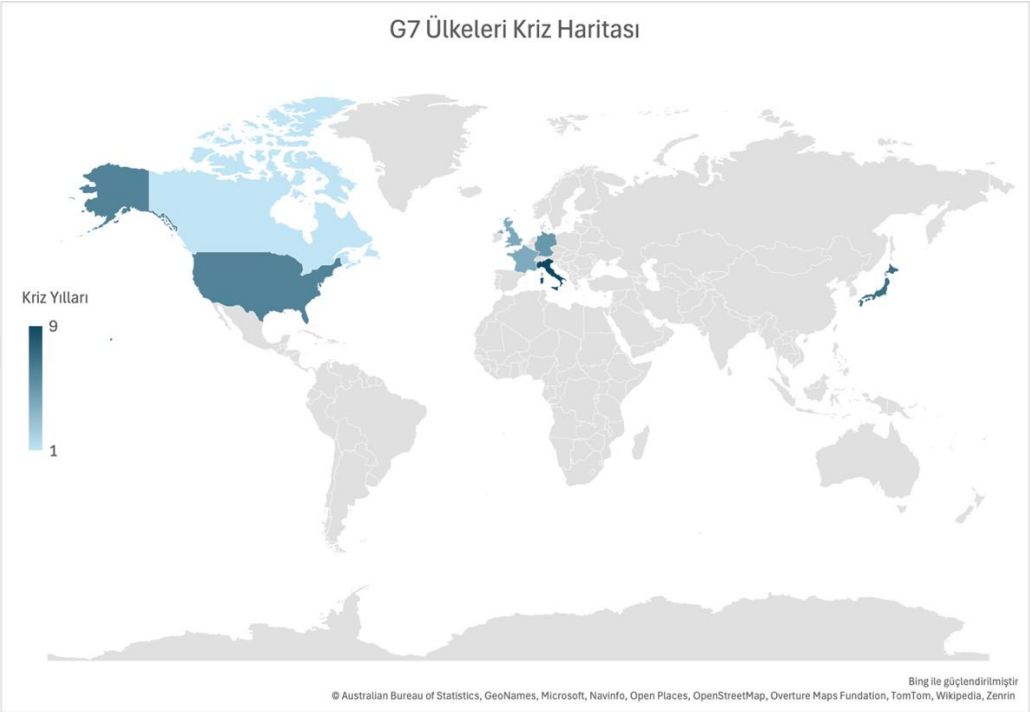
Finansal krizler ekonomik faaliyetler üzerinde büyük zararlı etkilere sahiptir ve bu nedenle geniş bir araştırmanın odak noktası olmuştur. G7 ülkeleri, küresel finansal sistemde belirleyici bir rol oynayarak sermaye akışlarını yönlendiren, rezerv para birimlerini ihraç eden ve uluslararası finansal düzenlemelerin şekillenmesinde etkili olan başlıca ekonomilerdir. Bankacılık sektörü açısından bu ülkeler dünya çapında sistemik öneme sahip bankalara ev sahipliği yapmakta ve Basel düzenlemeleri gibi küresel finansal istikrar çerçevelerinin oluşturulmasına öncülük etmektedir.

Bu çalışma, 1870-2020 yılları arasında G7 ülkeleri için makro finansal veriler kullanarak finansal kriz tahmini için erken uyarı modelleri geliştirmeyi amaçlamaktadır. Aynı zamanda makine öğrenimi tekniklerinin finansal kriz tahmininde nasıl etkili bir şekilde kullanılabileceğini ve hangi makroekonomik göstergelerin bu tahminlerde kritik rol oynadığını göstermektedir. Bu çalışmanın önemli katkılarından biri tahmin modelinin güvenilirliğini ekonometri uzmanlarına ve politika yapıcılara gösterebilmek amacıyla makine öğrenimi (ML) modelinin yorumlanmasından elde edilen nedensel ilişkiler SHAP (SHapley Additive exPlanations) metodolojisi aracılığıyla analiz edilmesidir. Lundberg ve Lee (2017) tarafından geliştirilen SHAP, açıklanabilir yapay zekâ (XAI) yaklaşımlarından biri olup her bir özelliğin tahmin edilen sonuç üzerindeki mutlak etki düzeyini ve aynı zamanda bu etkinin yönünü (olumlu veya olumsuz) ölçebilen güçlü bir makine öğrenimi yorumlama tekniği olarak kullanılmaktadır.

Çalışmada kullanılan SHAP analizi finansal piyasalar için sistemik bankacılık krizi altında yatan nedenleri belirlemek için etkili bir yöntem sunmaktadır. En ilgili unsurların belirlenmesi, paydaşların finansal krizlerle ilişkili riskleri daha iyi tahmin etmelerini ve en aza indirmelerini sağlamaktadır. Çeşitli ülkelerden elde edilen deneyimlerin bir araya getirilmesi finans ve bankacılık düzenlemelerinde hem küresel eğilimleri hem de yerel gerçekleri dikkate alan kapsamlı bir yaklaşıma duyulan ihtiyacı vurgulamaktadır.

Şekil 15’te G7 Ülkelerinde yaşanan finansal kriz yoğunluğu haritası oluşturulmuştur. Önerilen yöntem, Şekil 16'da gösterildiği gibi altı aşamadan oluşan sistematik bir veri analizi ve modelleme sürecidir. Bu süreç şu adımları içermektedir: veri toplama, veri ön işleme, sınıf dengesizliği giderme, model oluşturma, performans değerlendirme ve XAI ile sonuçların yorumlanması. Bu adımlar, veri analizi sürecinin güvenilir ve anlaşılır sonuçlar üretmesini hedeflemektedir.

Şekil 15: G7 Ülkelerinde Yaşanan Finansal Kriz Yoğunluğu



Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 16: Yöntem Akışı



Kaynak: Yazar tarafından oluşturulmuştur.

Çalışmanın ikinci bölümünde, kapsamlı bir literatür taraması sunulmuş, üçüncü bölümünde metodolojiye yer verilerek uygulanan makine öğrenme modeli ve Shapley değeri çerçevesi özetlenmiştir. Dördüncü bölümde veri seti ile tahmin edici değişkenlere ilişkin detaylı bilgi verilmiştir. Bu bölümde ayrıca Shapley değerleri aracılığıyla tahmin edicileri göreli önem düzeyleri ortaya koyulmuştur. Son olarak beşinci bölümde, çalışmanın temel bulguları özetlenerek ekonomik yorumuna yer verilmiştir.

Mevcut literatürde, G7 ülkelerinde sistemik bankacılık krizlerinin makine öğrenimi tabanlı tahminine odaklanan çalışmaların yetersizliği göze çarpmaktadır. Bu çalışma, literatürdeki bu eksikliği gidermek üzere, gelişmiş ekonometrik analizler ve makine öğrenimi tekniklerinin (özellikle XGBoost algoritmasının) entegrasyonu ile zaman serisi verilerinin daha etkin bir şekilde değerlendirilmesini hedeflemektedir. Çalışmanın özgün katkıları arasında, dengesiz veri kümeleri için uygun veri önişleme yöntemlerinin uygulanması, model doğrulama süreçleriyle XGBoost modelinin etkinliğinin titizlikle değerlendirilmesi ve SHAP analizleri aracılığıyla finansal krizlerin tahmininde rol oynayan faktörlerin kapsamlı bir şekilde incelenmesi yer almaktadır. Bu sayede, finansal krizlerin erken uyarısı için daha sağlam ve yorumlanabilir bir modelleme çerçevesi sunulmaktadır.

3.1. LİTERATÜR TARAMASI

Finansal krizlerin köklü bir geçmişe sahip olmasına karşın ülkeler arası panel veri setlerine dayalı erken uyarı modellemeleri 1990'lı yılların sonlarına doğru Kaminsky ve Reinhart (1999), Berg ve Pattillo (1999) gibi öncü çalışmalarla literatürde nispeten yeni bir uygulama alanı olarak ortaya çıkmıştır. Bu öncü makaleler, finansal krizlerin tarihlerine ilişkin veri setleri derleyerek hangi makro-finansal büyüklüklerin bu olayları öngörmede etkili olduğunu araştırmıştır. Söz konusu dönemde erken uyarı sistemlerinde yaygın olarak kullanılan iki temel yöntem sinyal yöntemi ve logit modeli olmuştur. Sinyal yöntemi, bir zaman serisini (örneğin, yıllık kredi büyümesi veya başka bir risk ölçüsü) analiz ederek önceden belirlenen bir eşiği aşan değerleri bir uyarı sinyali olarak kabul etmiştir. Logit modeli ise kriz durumunu (veya kriz öncesi dönemi temsil eden bir kukla değişkenini) doğrudan bir dizi makro-finansal değişken aracılığıyla açıklamayı hedeflemiştir. Bu ilk çalışmaların ardından finansal krizlerde öne çıkan makroekonomik ve finansal göstergelerin belirlenmesine yönelik çok sayıda çalışma literatüre kazandırılmıştır.

2008 Küresel Finans Krizi'nin ardından erken uyarı sistemlerine olan ilginin yeniden artmış olduğu Reinhart ve Rogoff (2011), Schularick ve Taylor (2012), Laeven

ve Valencia (2012), Babecký vd. (2014) çalışmalarıyla birlikte görülmektedir. Bu alanda kullanılan veri setleri önemli ölçüde genişletilmiştir. Elde edilen sonuçlar ülke ve veri setine göre farklılık göstermekle birlikte 2008 sonrası yapılan araştırmalar, özellikle özel sektör kredileri ve kredilerin gayri safi yurt içi hasılaya (GSYH) oranının, bankacılık krizlerinin güçlü belirleyicileri olduğunu gösteren önemli bulgular sunmuştur. Örneğin, Jordà, Schularick ve Taylor (2017) ve Tölö (2020) 1870-2016 yılları arasında finansal krizi "bir ülkenin bankacılık sektörünün banka iflasları yaşadığı, temerrüt oranlarında keskin artışların yaşandığı, kamu müdahalesi, iflas veya finansal kurumların zorunlu birleşmesiyle sonuçlanan büyük sermaye kayıplarının eşlik ettiği olaylar" olarak tanımlayan veri setini kullanmıştır.

Son dönemdeki literatür kriz tahmininde logit modellerin ötesine geçerek makine öğrenimi yöntemlerine yönelmiştir. Bu kapsamda, karar ağaçları ve yapay sinir ağları da dahil olmak üzere çeşitli makine öğrenimi algoritmaları araştırılmıştır. Bazı çalışmalar makine öğrenimi yöntemlerinin geleneksel ekonometrik modellere kıyasla daha iyi performans gösterdiğini ortaya koymuş olsa da logit modellere kıyasla makine öğrenimi yöntemlerinin etkinliği konusundaki tartışmalar hala devam etmektedir. Bu tartışmaların temelinde makine öğrenimi yöntemlerinin kriz öncesi gelişmeler için doğrusal olmayan kuralları belirleme potansiyeli yatmaktadır. Ancak mevcut literatürde tahmin süreçlerinde zaman serisi bilgilerinin tam olarak kullanılmadığı görülmektedir.

Geçmişte finansal krizlerin tahmini için yaygın olarak kullanılan modellerin aksine Dabrowski vd. (2016) tarafından yapılan bir çalışmada makine öğrenimi modellerinin geleneksel logit modellerine ve sinyal çıkarma yöntemlerine kıyasla daha üstün bir performans sergilediği gösterilmiştir. Vašíček vd. (2017) finansal krizleri öngörecek göstergeleri belirlemek için 25 OECD ülkesinden elde edilen veriler üzerinde Bayesian Model Ortalaması uygulamış ve doğrusal modellerin finansal dinamikleri yakalayamadığı ve finansal stresi tahmin edemediğini vurgulamıştır.

Makine öğrenmesi yöntemleriyle finansal krizleri tahmin etmek için Alessi ve Detken (2018), tarafından yürütülen bir araştırmada, Avrupa Birliği (AB) bankacılık krizleri veri seti kullanarak sistemik riski tespit etmek amacıyla rastgele orman algoritmasına dayalı bir erken uyarı sistemi geliştirilmiştir. Bu sistemde, makroekonomik

göstergeler risk tahmininde kullanılacak temel değişkenler olarak belirlenmiştir. Çalışmanın sonuçları, rastgele orman modelinin kayda değer bir tahmin performansı sergilediğini ve makroekonomik verilerden yararlanarak erken uyarı sistemlerinin oluşturulması konusunda gelecek vaat ettiğini ortaya koymuştur. Bu bulgular, rastgele orman gibi makine öğrenimi tekniklerinin finansal istikrarın izlenmesi ve risk yönetimi alanlarında önemli katkılar sağlayabileceğini göstermektedir. Chatzis vd. (2018), Rastgele Orman, sınıflandırma ağaçları, Destek Vektör Makineleri (DVM), XGBoost ve İleri Beslemeli Sinir Ağları'nın (FFNN) performansını ampirik olarak karşılaştırmışlar ve en iyi sonucu XGBoost yönteminin verdiği sonucuna ulaşmışlardır.

Tran vd. (2022) tarafından gerçekleştirilen yakın tarihli bir araştırma, Vietnam borsasında 2010-2021 yılları arasında işlem gören şirketlere ait bir veri seti üzerinde karmaşık makine öğrenimi modellerinin tahmin sonuçlarını yorumlamak için Shapley değerlerinden yararlanmıştır. Bu çalışmanın bulguları, aşırı gradyan artırma (extreme gradient boosting) ve rastgele orman (random forest) modellerinin diğer makine öğrenimi modellerine kıyasla daha yüksek performans gösterdiğini ortaya koymuştur. Çalışmanın dikkat çekici bir yönü ise yazarların Shapley değerlerini kullanarak her bir özelliğin tahmin sonuçları üzerindeki etkisini detaylı bir şekilde analiz etmesi ve bu sayede teorik çerçevede öngörülmeyen ilişkiler hakkında ek bilgiler sunmalarıdır. Bu yaklaşım, makine öğrenimi modellerinin karar verme süreçlerini daha şeffaf hale getirerek ilgili alanlardaki araştırmacılar ve uygulayıcılar için değerli içgörüler sağlamaktadır. Liu vd. (2022), daha etkili tahmin göstergelerini belirlemek ve makine öğrenimi modellerinin nedensel ilişkilerini analiz etmek amacıyla Shapley değerli ayrıştırma ve Shapley regresyon yöntemlerini kullanmışlardır. Chen vd. (2024) logit modeli ve diğer derin öğrenme modellerini karşılaştırarak erken uyarı sisteminin yorumlanabilirliği için Shapley değer ayrışımı hesaplamıştır. Çalışmanın ampirik sonuçları TCN'nin diğer modellerden daha iyi performans gösterdiğini ve hisse senedi fiyatı ve reel GSYİH büyümesinin kriz tahmininde en büyük katkıya sahip olduğunu göstermektedir.

Bu çalışma, finansal krizler bağlamında gelişmiş ekonometrik ve makine öğrenimi teknikleri aracılığıyla G7 ülkelerinde sistemik bankacılık krizlerini tahmin ederek literatüre önemli bir katkı sağlamaktadır. Öncelikle, dengesiz veri kümeleri için uygun

olan yöntemler kullanılarak veri önişleme aşaması detaylı bir şekilde tamamlanmıştır. İkinci olarak söz konusu problemi ele almak için ilgili bir makine öğrenimi tekniği olan XGBoost yöntemi kapsamlı bir şekilde incelenmiştir. Daha sonra bu modelleme tekniğinin etkinliğini değerlendirmek amacıyla model doğrulama süreçleri uygulanmış ve performans ölçütleri kullanarak modelin başarımı değerlendirilmiştir. Son olarak SHAP analizleriyle finansal kriz tahmin görevini yerine getirmek için kullanılabilecek ve büyük finansal piyasaların tüm yelpazesini kapsayan genişletilmiş bir açıklayıcı değişkenler kümesinin kapsamlı bir incelemesi sunulmuştur.

3.2. METODOLOJİ

3.2.1. Aşırı Gradyan Artırma (Extreme Gradient Boosting – XGBOOST)

Chen ve Guestrin (2016) tarafından geliştirilen XGBoost (Extreme Gradient Boosting), Friedman (2001) tarafından önerilen boosting algoritmasını temel alan bir yaklaşımdır. Bu algoritma, model karmaşıklığını düşürmek, aşırı öğrenmeyi engellemek ve öğrenme sürecini hızlandırmak için amaç fonksiyonunda düzenlileştirme (normalizasyon) tekniklerini kullanır. Bu özellik, modelin karmaşıklığını denetim altında tutarak daha iyi bir genelleme performansı sergilemesine katkı sağlamaktadır. Ayrıca XGBoost, karar ağaçlarının verimli bir şekilde bir araya getirilmesiyle oluşturulan bir topluluk modelidir ve bu sayede tek başına kullanılan yöntemlere kıyasla daha yüksek tahmin performansı sunar. Bu özellikleriyle XGBoost, makine öğrenimi uygulamalarında yaygın olarak tercih edilen bir algoritma haline gelmiştir.

Minimize edilecek optimizasyon fonksiyonu eşitlik 17'deki gibidir. Burada $L^{(t)}$ ile ifade edilen bir kayıp fonksiyonudur. $\Omega(\phi_t)$ ise modelin karmaşıklığını tanımlayan bir düzenlileştirme terimidir. Amaç, $L^{(t)}$fonksiyonunu minimize edecek ϕ_t değerini tespit etmektir. Bu optimizasyon süreci modelin hem eğitim verilerine iyi uyum sağlamasını hem de aşırı öğrenme (overfitting) riskini azaltarak genelleme yeteneğinin artırılmasını hedeflemektedir. Sınıflandırma görevlerinde XGBoost, önceki modellerin hatalarını tahmin eden yeni modelleri yinelemeli olarak inşa ederek ve bu modelleri birleştirerek

nihai tahmine ulaşır. XGBoost'un amaç fonksiyonu, bir kayıp fonksiyonu ve bir düzenlileştirme teriminden oluşur. Kayıp fonksiyonu tahmin edilen ve gerçek değerler arasındaki farkı ölçerken, düzenlileştirme terimi aşırı öğrenmeyi engellemektedir.

$$L^{(t)} = \sum_{k=1}^{n} l\left(y_k, \hat{y}_k^{(t-1)} + \phi_t(x_k)\right) + \Omega(\phi_t) \quad (17)$$

XGBoost algoritmasının hesaplama hızı ve bellek kullanımındaki optimizasyon, bu tekniği özellikle büyük veri kümeleri için elverişli kılmaktadır (Mitchell ve Frank, 2017). Ayrıca XGBoost, aşırı öğrenme riskini önemli ölçüde azaltan hem L1 (Lasso) hem de L2 (Ridge) düzenleme algoritmalarını bünyesinde barındırmaktadır (Osman vd., 2024). Algoritmanın dikkate değer bir diğer özelliği ise eksik verileri dahili olarak işleyebilmesi ve bu sayede kapsamlı veri ön işleme ihtiyacını azaltmasıdır (Dhaliwal vd., 2018).

Çok sayıda avantaj sunmasına rağmen XGBoost bazı zorlukları da beraberinde getirmektedir. Özellikle çok sayıda ağaç ve özellik ile çalışıldığında ortaya çıkan modeller karmaşık bir yapıya sahip olabilmekte ve yorumlanması güçleşebilmektedir (Meng vd., 2020). XGBoost'ta hiperparametrelerin ayarlanması, özenli bir çalışma gerektiren ve zaman alıcı bir süreç olabilir (Qin vd., 2021). Son olarak XGBoost modelleri, özellikle küçük veri kümelerinde aşırı öğrenmeye yatkın olup bu durum sağlam bir düzenleme gerektirmektedir (Aksoy ve Genc, 2023). Bu nedenle modelimizde SMOTE tekniği uygulanmıştır.

3.2.2. SHAP Analizi

Bu çalışma, işbirlikçi oyun teorisinin temel kavramlarından olan Shapley değerlerini (Shapley, 1953) kullanarak makine öğrenimi modellerindeki öngörücülerin katkılarını değerlendirmeyi amaçlamaktadır. Shapley değerleri, her bir öngörücünün model çıktısına yaptığı katkıyı nicelendirmek için kullanılmaktadır. Lundberg ve Lee (2017) tarafından geliştirilen SHAP (SHapley Additive exPlanations) kavramı ise her bir özelliğin tahminlere olan katkısını hesaplayarak makine öğrenimi modellerinin yaptığı tahminleri daha anlaşılır kılmayı hedeflemektedir. Bu sayede karmaşık modellerin karar alma süreçleri şeffaflaşır.

3.3. UYGULAMA

3.3.1. Veriler

G7 ülkeleri için kullanılan veriler Jórda-Schularick-Taylor makro tarih veri tabanından alınmıştır (Jordà vd., 2017). Veri seti, sistemik finansal krizleri "bir ülkenin bankacılık sektörünün, kamu müdahalesi, iflas veya finansal kurumların zorunlu birleşmesi ile sonuçlanan büyük sermaye kayıplarının eşlik ettiği temerrüt oranlarında keskin artışlar yaşadığı olaylar" olarak sınıflandırmaktadır (Schularick ve Taylor, 2012). Çalışmada finansal piyasadaki kriz durumu 0 ve 1 değerlerine sahip ikili (binary) bir değişken olarak tanımlanmıştır. Bu yaklaşım, ikili hedefli makine öğrenimi yöntemlerinin kullanılmasını mümkün kılmakta ve hedef değişkenin daha kolay tahmin edilmesini sağlamaktadır. Çalışmada kriz durumunun bağımlı değişken olarak ele alınması yalnızca aşırı uyum olasılığını azaltmakla kalmayıp aynı zamanda piyasadaki kriz durumunun daha net bir şekilde temsil edilmesine olanak tanımaktadır. Sonuç olarak bu yaklaşım makine öğrenimi modellerinin tahmin doğruluğunu artırmaya katkı sağlamaktadır.

Sistemik kriz, bir bankanın yaşadığı sorunların diğer bankaları da etkileyerek tüm finansal sistemi tehdit ettiği bir durumdur. Düşük sermaye yeterliliği, yüksek faiz oranları ve yüksek enflasyon gibi faktörler sistemik riski artırabilir. Sistematik bankacılık krizlerini tahmin etmek için kullanılan göstergeler arasında kredi ile ilgili göstergeler, makroekonomik göstergeler (GSYH) ve piyasa ile ilgili göstergeler (faiz oranları) bulunmaktadır (Nazareth ve Ramana Reddy, 2023). Makroekonomik ortamı ve ekonomik faaliyetleri yansıtmak amacıyla GSYH büyüme oranı ve enflasyon oranı olmak üzere iki standart konjonktür göstergesi kullanılmıştır. Ilımlı GSYH büyümesi ekonomik istikrarı yansıtırken hızlı veya düşük GSYH büyümesi kırılganlığın endişe verici bir işareti olabilir (Kauko, 2014). Aşırı ısınmış ekonomiler, sermaye akışları yoluyla sınır ötesine aktarılabilen dışsal risklere karşı daha savunmasızdır (Jordà vd., 2011). Diğer yandan, yavaş veya olumsuz ekonomik gelişmeler reel ekonomik zayıflıklara işaret ederek potansiyel olarak krizlere yol açabilir. Benzer şekilde yüksek enflasyon makro-finansal istikrarsızlıklara işaret edebilirken, çok düşük enflasyon veya deflasyon da tüketici

harcamalarını kısıtladığı ve hatta resesyona neden olabileceği için endişe verici bir durumdur.

Geçmişte yaşanan çok sayıda kriz ve 2007/2008 küresel finans krizi öncesinde birçok sanayi ülkesinde büyük cari açıkların görülmesi, cari işlemler dengesizliğinin makro-finansal kırılganlığın potansiyel bir kaynağı olduğunu ve bu nedenle düzenleyicilerin ilgi odağı olması gerektiğini ortaya koymaktadır (Obstfeld, 2012). Bu nedenle, sistemik kriz tahminlemesi göstergelerinde cari hesap/GSYH oranı bir gösterge olarak yer almaktadır.

1980'lerde Japonya'da, 1990'larda İskandinav ülkelerinde ve 2000'lerde ABD'de görülen kredi kaynaklı varlık fiyatı balonları, önemli kredi krizlerine yol açmıştır (Brunnermeier ve Oehmke, 2013). Bu nedenle, kredi gelişmelerini analiz etmek amacıyla finans dışı özel sektöre sağlanan toplam kredinin GSYH içindeki payı kullanılmıştır.

Tablo 13: Kriz Tahminlemesinde Kullanılan Değişkenler ve Açıklamaları

	Değişkenler
crisis	Sistemik finansal krizler (Dummy: 0-1 göstergesi)
rgdp_gr	Reel GSYİH büyüme oranı (2005=100)
inv_gdp	Yatırımın GSYİH'ye oranı
cpi_rate	Tüketici fiyatlarındaki yüzdesel değişim (1990=100)
broadmoney	Geniş para arzı büyüme oranı (nominal, yerel para birimi)
rate	Uzun dönem vadeli faiz oranı (nominal, yıllık yüzde)
xrusd	USD döviz kuru (yerel para birimi/USD)
ltd	Bankalar, kredilerin mevduata oranı (%)
lev	Bankalar, sermaye oranı (yüzde)
cur/gdp	Cari işlemler hesabı (nominal, yerel para) / Gerçek kişi başı GSYİH (endeks, 2005=100)
loans/gdp	Finansal olmayan özel sektöre verilen toplam krediler / Gerçek kişi başı GSYİH (endeks, 2005=100)

Kaynak: Yazar tarafından oluşturulmuştur.

Bu çalışmada finansal krizlerin makine öğrenmesi yöntemleriyle tahminlenmesi kapsamında aşağıda Tablo 13'te yer alan değişkenler kullanılmıştır. Model parametrelerini optimize etmek ve genelleme yeteneğini değerlendirmek amacıyla sırasıyla eğitim veri seti (X) ve test veri seti (y) kullanılmış ve veri seti, %80'i modelin eğitimi, %20'si ise test süreci için ayrılarak analiz süreci yürütülmüştür.

3.3.2. Model Değerlendirme

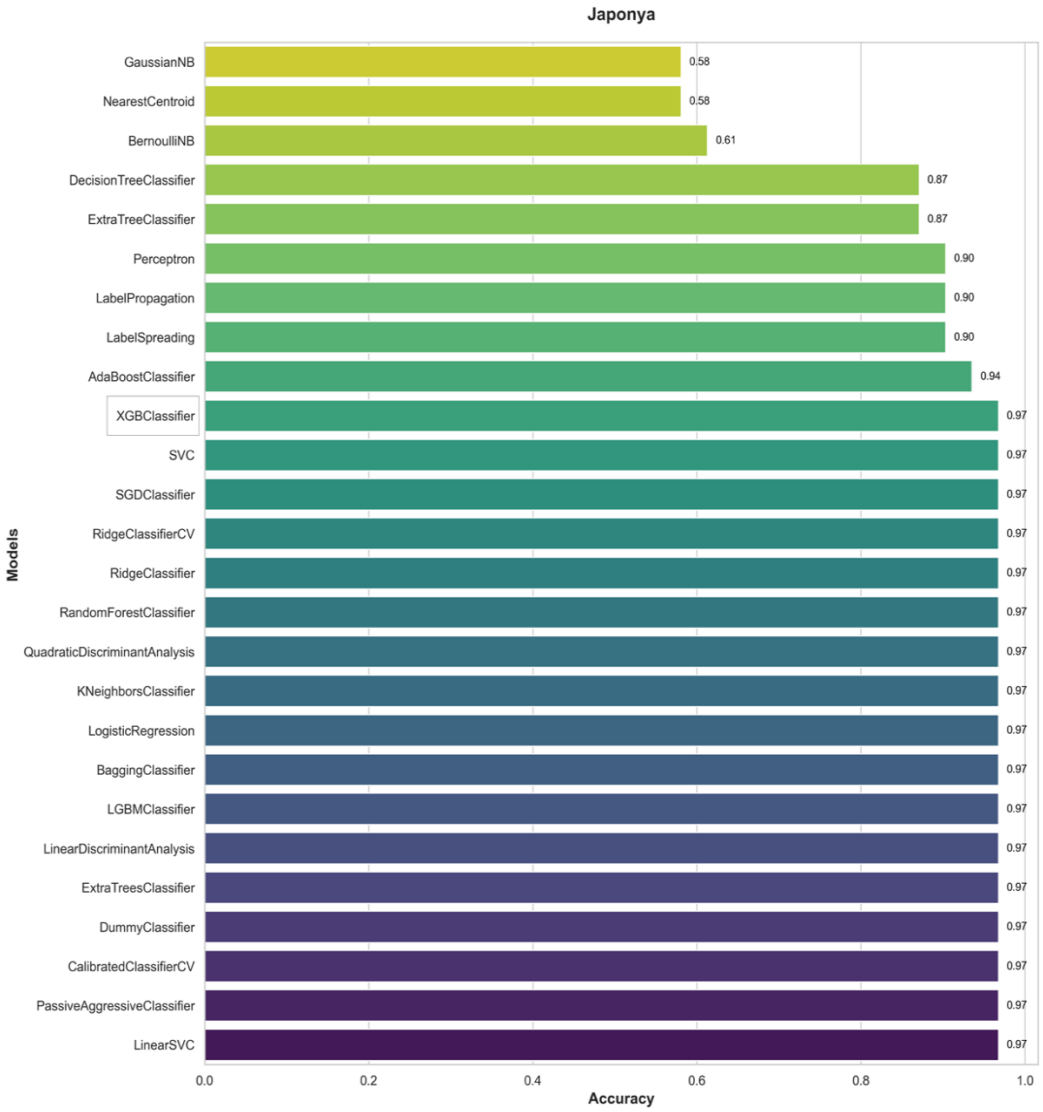
LazyPredict parametre optimizasyonu gerektirmeksizin, birkaç satır kod aracılığıyla çeşitli modellerin kolaylıkla denenmesine imkân vermektedir (Shankarpandala, 2024). Bu çalışmada, LazyPredict kütüphanesi aracılığıyla LazyClassifier kullanılarak veri analizinde yaygın olarak tercih edilen 26 farklı sınıflandırıcı modelinin performansları karşılaştırılmış ve elde edilen sonuçlar neticesinde, en yüksek genel doğruluk(accuracy) oranına sahip XGBoost modeli Tablo 14'te sunulan tahmin sonuçlarıyla detaylandırılmıştır. Şekil 17'de ise model sonuçları doğruluk oranına göre sıralanmıştır.

Tablo 14: G7 Ülkeleri için LazyPredict XGBoostClassifier Tahmin Sonuçları

Ülkeler	Doğruluk Oranı	F1 Skoru	İşlem Süresi
ABD	0.9032	0.8879	0.0585
Almanya	0.9677	0.9519	0.0704
İngiltere	0.9677	0.9519	0.0545
Fransa	10.000	10.000	0.0586
İtalya	10.000	10.000	0.0588
Japonya	0.9677	0.9519	0.0722
Kanada	10.000	10.000	0.0527

Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 17: Japonya için LazyClassifier Tahmin Sonuçları



Kaynak: Yazar tarafından oluşturulmuştur.

3.3.3. Model Tanımı ve XGBoost Sonuçları

Çalışmada öncelikle dengesiz veri setlerindeki azınlık sınıfını güçlendirmek ve sınıflandırıcı performansını artırmak amacıyla resampling teknikleri arasında en sık kullanılan yöntem olan SMOTE (Synthetic Minority Over-sampling Technique) yöntemi kullanılmıştır. SMOTE, azınlık sınıfına ait sentetik örnekler oluşturarak veri setindeki

sınıf dengesizliğini azaltır ve sınıflandırıcıların azınlık sınıfını daha iyi öğrenmesini sağlar (Chawla vd., 2002; He vd., 2024). Sonrasında ise finansal krizlerin potansiyel göstergelerini tespit etmek amacıyla aşırı gradyan artırma tekniğinden yararlanılmıştır. Uygulanan metodolojide, G7 ülkelerinde meydana gelen bankacılık krizlerinin potansiyel tahmin değişkenlerinin belirlenmesinden önce XGBoost algoritmasının model tanılama yeteneği ve tahmin doğruluk düzeyi ayrıntılı olarak analiz edilmiştir. Elde edilen bulgular, modelin güvenilirliğini ve öngörü kapasitesini değerlendirme imkânı sunmaktadır.

Tablo 15: Hiperparametre Aralıkları

Parametreler	**Aralık**
max_depth	[3, 5, 7, 9, 11]
subsample	[0.7, 0.8, 1]
n_estimators	[50, 75, 100, 300]
learning_rate	[0.05, 0.1, 0.2]
gamma	[0, 0.1, 0.2]
colsample_bytree	[0.7, 0.8, 0.9, 1]
min_child_weight	[1, 3, 5]

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 16: Model iyileştirme sonrası en iyi parametreler

Parametreler	**ABD**	**Almanya**	**İngiltere**	**Fransa**	**İtalya**	**Japonya**	**Kanada**
max_depth	3	3	3	3	7	5	3
subsample	0.7	0.8	1	0.8	1	0.8	1
n_estimators	100	300	100	75	75	300	50
learning_rate	0.20	0.30	0.05	0.20	0.10	0.20	0.05
gamma	0.1	0.0	0.0	0.2	0.0	0.2	0.0
colsample_bytree	0.8	0.8	0.7	0.7	0.7	0.9	0.7
min_child_weight	1	1	3	1	1	1	1

Kaynak: Yazar tarafından oluşturulmuştur.

Model karmaşıklığı, özellik örneklemesi ve öğrenme oranı gibi çeşitli ayarlama parametrelerine ilişkin yaklaşımlar ülkeler arasında farklılık göstermektedir. Bu farklılıklar her ülkenin kendine özgü ekonomik koşulları ve veri setlerinin nitelikleriyle

ilişkilendirilmektedir. Bu tespitlerin analizi, model performansını optimize etmek ve güvenilir makroekonomik tahminler üretmek açısından büyük önem arz etmektedir. Tablo 15 uygulanan model için hiperparametre aralıklarını verirken Tablo 16'da G7 ülkelerinden elde edilen sonuçlar ışığında, finansal krizleri en yüksek model performansı ile tahminleyen optimal parametre değerleri belirtilmiştir. Bu sonuçlar, belirli parametre değerlerinin model başarımı üzerindeki kritik etkisini vurgulamaktadır. Dolayısıyla söz konusu parametrelerin dikkatli bir şekilde ayarlanması, her ülkenin veri setinin özgün niteliklerine göre uyarlanmış, sağlam ve doğru modeller geliştirilmesi için elzemdir.

3.4. AMPİRİK BULGULAR

3.4.1. XGBoost Performans Sonuçları

Tablo 17'de sunulan performans değerlendirme metrikleri, G7 ülkelerinde XGBoost yöntemiyle geliştirilen modellerin farklı senaryolardaki tahmin yeteneklerini ve güvenilirliğini analiz etmek amacıyla kullanılan temel istatistiksel göstergeleri kapsamlı bir şekilde özetlemektedir.

Tablo 17: XGBoost Sınıflandırıcının Tahmin Performans Sonuçları

Metrik	ABD	Almanya	İngiltere	Fransa	İtalya	Japonya	Kanada
Doğruluk	0.828	1	0.867	0.929	0.909	0.933	1
95% Güven Aralığı	(0.690, 0.965)	(1.000, 1.000)	(0.745, 0.988)	(0.833, 1.024)	(0.811, 1.007)	(0.844, 1.023)	(1.000, 1.000)
Duyarlılık	0.667	1	0.556	0.667	0.818	0.875	1
Özgüllük	0.941	1	1	1	0.955	0.955	1
PPV	0,889	1	1	1	0,9	0,875	1
NPV	0,8	1	0,84	0,917	0,913	0,955	1

Kaynak: Yazar tarafından oluşturulmuştur.

Modellerin doğruluğu ülkeler arasında farklılık göstermekte olup Almanya ve Kanada'da %100'lük bir doğruluk oranı gözlenirken, diğer ülkelerde bu oran %82,8 (ABD) ile %93,3 (Japonya) arasında değişmektedir. Almanya ve Kanada'daki bu yüksek

doğruluk, modelin bu ülkelerdeki verileri hatasız sınıflandırdığını göstermektedir. Bu doğruluk tahminleri için güven aralıkları da farklı hassasiyet seviyelerini yansıtmakta olup Almanya ve Kanada hariç diğer ülkelerde güven aralıkları doğruluk değerleriyle uyumlu olarak genişlemektedir (örneğin ABD: 0,690-0,965).

Duyarlılık(hassasiyet) ve özgüllük değerleri incelendiğinde pozitif ve negatif örneklerin tespitinde model performansını değerlendirmek için çok önemlidir. Almanya ve Kanada'nın modeli mükemmel hassasiyet ve mükemmel özgüllük elde ederek bir kez daha öne çıkmaktadır. İngiltere (%55,6) en düşük duyarlılığa sahiptir. İngiltere'deki düşük duyarlılık, modelin finansal kriz yıllarını tespit etmede zorlandığını ve bazı kriz dönemlerinin gözden kaçabileceğini göstermektedir. Almanya, Kanada, Fransa ve Birleşik Krallık'ta %100 özgüllük gözlenmiştir, bu da bu ülkeler için modelin tüm kriz olmayan tarihleri hatasız bir şekilde tespit ettiğini göstermektedir. Bununla birlikte modelde 0 duyarlılığa sahip olan ülke yoktur, bu da kriz dönemlerini tespit etmede tamamen başarısız olan ülke modeli olmadığı anlamına gelmektedir.

Pozitif tahmin değeri (PPV) ve negatif tahmin değeri (NPV) sırasıyla doğru pozitif ve negatif tahminlerin yüzdesini temsil etmektedir. Ülkeler genelinde yüksek PPV ve NPV değerleri oldukça güvenilir tahminlere işaret etmektedir. Tespit oranı ise gerçek pozitif vakaların toplam vaka sayısı içindeki oranını ifade etmektedir. Almanya ve Kanada %100 kriz dönemi tespit oranı ile en yüksek başarıyı gösterirken diğer ülkelerde bu oran ABD (%27,6) ile Japonya (%27,3) arasında değişmektedir.

Tablodaki veriler, modelin Almanya ve Kanada'da genel olarak mükemmel bir performans sergilediğini, diğer ülkelerde de yüksek doğruluk oranlarına ulaştığını göstermektedir. Ancak, İngiltere'nin duyarlılık ve tespit oranlarındaki düşüklükler, modelin performansının ülkelere göre değiştiğini ve bazı ülkelerde ek optimizasyonların gerekebileceğini işaret etmektedir. Modelin veriye veya popülasyon özelliklerine bağlı olarak uyarlanması, özellikle düşük performans gösteren ülkelerde daha iyi sonuçlar elde etmek için önemli olabilir.

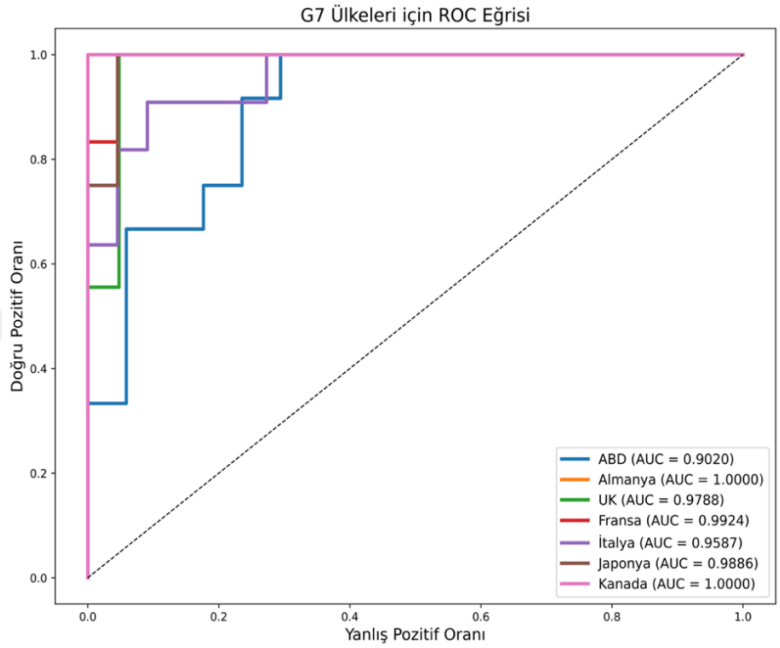
Tanı kriterleri ülkeler arasında aşırı gradyan artırma modellerinin performansında kayda değer farklılıklar olduğunu göstermektedir. Özellikle Kanada ve Almanya modelleri, tüm değerlendirme metriklerinde sürekli olarak üstün bir performans

sergileyerek güçlü tahmin potansiyellerine işaret etmektedir. Buna karşılık İngiltere için özellikle duyarlılık oranlarındaki düşüklükler, modelin performansının ülkelere göre değiştiğini ve bazı ülkelerde ek optimizasyonların gerekebileceğini işaret etmektedir. Bu tür farklılıklar güvenilir ve doğru tahminler elde etmek amacıyla uygulamalı makroekonomi çalışmalarında bağlama özgü model ayarlaması ve doğrulamanın kritik önemini vurgulamaktadır. Bu araştırma, modellerin performansının kapsamlı bir özetini sunmakta, farklı ülke ortamlarındaki güçlü ve zayıf yönlerini vurgulamakta ve daha fazla model iyileştirmesi için öneriler sunmaktadır.

Finansal kriz tahmin sonuçlarının olasılık tahminleri olarak değerlendirilmesi, tahmin modellerinin performansını ölçmek için Alıcı İşletim Karakteristiği (ROC) eğrisi altında kalan alan (AUC) kullanımını desteklemektedir. AUC, sistemik finansal krizlerin öngörülmesine yönelik erken uyarı sistemleri literatüründe yaygın olarak kabul görmüş bir performans ölçütüdür (Alessi vd., 2015). Modeller, finansal kriz olasılığını 0 ile 1 arasında bir değer olarak çıktı vermektedir. Belirli bir h eşik değerinin aşılması durumunda, modelin gelecek yıl sistemik bir finansal kriz öngördüğü, aksi takdirde kriz öngörmediği şeklinde yorum yapılmaktadır.

Bununla birlikte Şekil 18'de G7 ülkeleri için sunulan XGBoost ROC eğrisi (Receiver Operating Characteristic Curve) ve AUC değerleri, modelin genel olarak yüksek bir performans sergilediğini göstermektedir; AUC değerlerinin büyük çoğunluğunun 0.90'ın üzerinde olması, sınıflandırıcının ayrım gücünün kayda değer düzeyde olduğunu desteklemektedir. ABD için elde edilen AUC değerinin (0.9020) diğer ülkelere kıyasla daha düşük olması, modelin bu ülke için daha az başarılı olduğunu göstermemekle birlikte verilerde daha fazla varyans veya sınıflandırma zorluğu olabileceğine işaret etmektedir. Elde edilen sonuçlar, XGBoost algoritmasının G7 ülkelerine yönelik sınıflandırma görevlerinde etkili bir modelleme aracı olduğunu ortaya koymaktadır.

Şekil 18: G7 Ülkeleri için XGBoost ROC Eğrisi ve AUC Değerleri

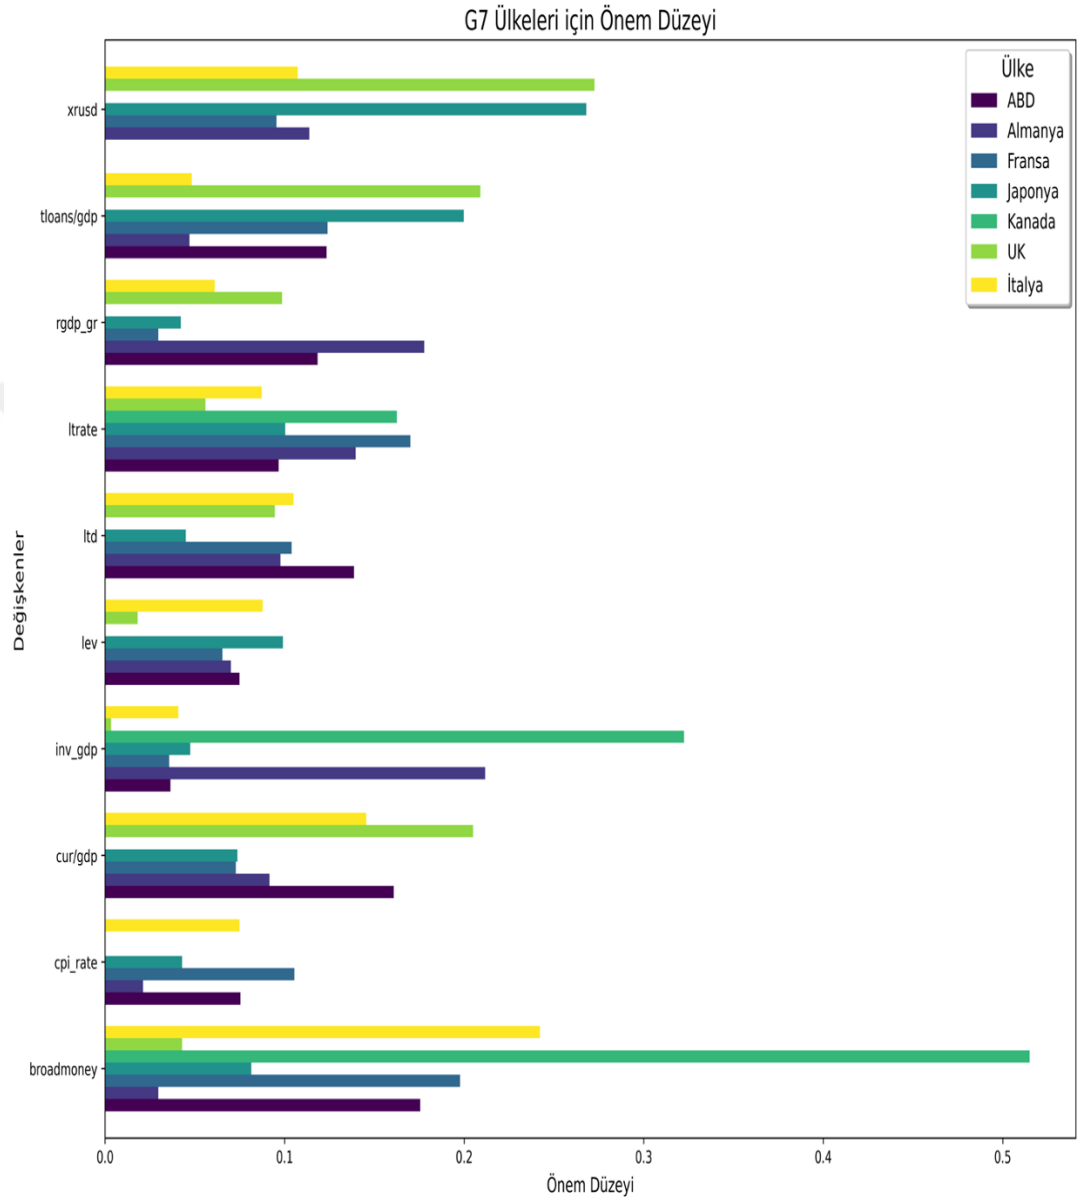


Kaynak: Yazar tarafından oluşturulmuştur.

3.4.2. Değişkenlerin Önem Düzeyleri

Şekil 19'da sunulan G7 ülkelerine ait sistemik finansal kriz dönemlerini tahminleyen XGBoost modellerindeki değişken önem düzeyleri, kriz öngörüsü için hangi göstergelerin daha belirleyici bir rol oynadığını ortaya koymaktadır. Tablo 18'de ise değişken önem düzeyleri detaylı bir şekilde sunulmaktadır. Her değişkenin, modelin tahmin başarısına ne ölçüde katkıda bulunduğunu temsil eden önem düzeyleri, ülkeler bazında farklılık göstermektedir.

Şekil 19: G7 Ülkeleri için Potansiyel Kriz Tahmincileri



Kaynak: Yazar tarafından oluşturulmuştur.

Kredilerin mevduata oranı (ltd), bankacılık sisteminin likidite durumu ve kredi verme kapasitesi hakkında bilgi sunmaktadır. İtalya, Fransa ve ABD'de bu değişkenin önemi, bankacılık sektörünün krizlere karşı duyarlılığını artırabilir. Bu ülkelerde bankaların likidite düzenlemelerinin (örneğin, Basel III kuralları) sıkılaştırılması ve

kredilerin sürdürülebilirliğinin sağlanması gerekmektedir. Bankalar için sermaye yeterlilik rasyosunun (lev) ABD, İtalya ve Japonya için önemli olması, bankacılık sektöründeki yapısal kırılganlıklara işaret edebilir. Bu doğrultuda bankaların sermaye yeterlilik oranlarının artırılması ve risk yönetimi standartlarının güçlendirilmesi önem taşımaktadır.

Tablo 18: G7 Ülkelerine ait Değişken Önem Düzeyleri

	ABD	Almanya	UK	Fransa	İtalya	Japonya	Kanada
broadmoney	0.17550	0.02965	0.04290	0.19775	0.24217	0.08140	0.51496
cur/gdp	0.16080	0.09158	0.20494	0.07281	0.14547	0.07369	0.00000
ltd	0.13862	0.09764	0.09462	0.10391	0.10497	0.04502	0.00000
loans/gdp	0.12340	0.04701	0.20900	0.12391	0.04826	0.19983	0.00000
rgdp_gr	0.11834	0.17778	0.09864	0.02963	0.06110	0.04221	0.00000
rate	0.09665	0.13956	0.05589	0.17006	0.08726	0.10036	0.16255
cpi_rate	0.07540	0.02116	0.00000	0.10544	0.07488	0.04289	0.00000
lev	0.07487	0.07013	0.01816	0.06532	0.08780	0.09909	0.00000
inv_gdp	0.03642	0.21172	0.00329	0.03573	0.04081	0.04746	0.32249
xrusd		0.11375	0.27258	0.09545	0.10729	0.26805	0.00000

Kaynak: Yazar tarafından oluşturulmuştur.

İtalya, ABD ve İngiltere için cari açığın GSYİH'ya oranının kriz tahmininde önemli olması, dış finansmana bağımlılığın sistemik risk yaratabileceğini göstermektedir. Bu ülkelerde dış ticaret açığını azaltmaya yönelik politikaların (örneğin, ihracat teşviki ve ithalatı ikame eden üretim) geliştirilmesi gerekmektedir.

Geniş para arzındaki büyüme oranı Kanada, İtalya, Fransa ve ABD gibi ülkelerde kriz olasılığını etkileyen en önemli faktörlerden biri olarak öne çıkarken para politikalarının etkin yönetimi ve likidite fazlasının kontrol altında tutulmasının önemini vurgulamaktadır. Bu durum, artan likiditenin varlık fiyatı balonları ve aşırı borçlanma gibi mekanizmalar yoluyla finansal istikrarsızlığa yol açabileceği yönündeki makroekonomik teorilerle uyumludur (Minsky, 1995). Para arzındaki genişleme, likidite fazlasına ve potansiyel varlık balonu oluşumuna zemin hazırlayarak krizleri tetikleyebilir. Nitekim,

Cardarelli vd. (2011) de benzer şekilde, aşırı likidite artışının kriz dönemlerinde finansal istikrarı tehdit edebileceğini göstermiştir. Ancak, bu bulgu tüm G7 ülkeleri için geçerli değildir. Özellikle Kanada'da para arzı büyümesinin kriz tahmininde belirleyici rol oynaması, finansal sistemin aşırı likidite bağımlılığını işaret etmektedir. Uzun vadeli faiz oranları ise borçlanma maliyetlerini ve yatırım kararlarını etkileyerek finansal istikrarı tehdit edebilir. Bu bağlamda, söz konusu ülkelerde merkez bankalarının para arzını yakından takip etmesi, para politikalarının faiz oranlarını dengeleyici bir şekilde yönetilmesi ve borçlanma maliyetlerinin kontrol altında tutulması finansal istikrar açısından kritik öneme sahiptir. Politika yapıcılar, ekonomideki aşırı likiditeyi yönetmek amacıyla zorunlu karşılıkları artırmak ve para arzındaki büyümeyi dengelemek için açık piyasa işlemleri gibi önlemler almalıdır. Para arzı artışının ekonomik temellerle uyumlu tutulması, aşırı likiditeden kaynaklanan spekülatif balonların oluşmasının önlenmesine yardımcı olacaktır.

Öte yandan, İngiltere ve Japonya gibi ülkelerde döviz kuru ve özel sektör kredilerinin GSYİH'ye oranı gibi değişkenler daha belirleyici rol oynamaktadır. Bu durum, dış finansman bağımlılığı ve özel sektörün borçluluk düzeyinin ülke özelindeki kurumsal ve finansal yapıya bağlı olarak farklı etkiler yaratabileceğini düşündürmektedir (Reinhart ve Rogoff, 2011). Döviz kurunun bu ülkelerdeki yüksek önemi, dış ticaret ve finansal piyasalar üzerindeki etkilerinden kaynaklanmaktadır. Döviz kuru dalgalanmalarını sınırlamak amacıyla aktif bir kur politikası izlenmesi ve kur risklerine karşı finansal sistemin güçlendirilmesi gerekmektedir. ABD, İngiltere, Fransa ve Japonya'da kredilerin GSYİH' ya oranı öne çıkmaktadır. Alessi ve Detken (2018) sonuçlarıyla uyumlu şekilde kredi/GSYİH oranları bir ülkenin konjonktürel gelişmelerden ziyade aşırı yapısal kaldıraç nedeniyle ne kadar kırılgan olduğunu değerlendirmede yardımcı göründüğünü ve bu nedenle büyüme oranları tarafından sağlanan bilgileri koşullandırmada faydalı olduğunu belirtmek mümkündür.

Almanya ve Kanada gibi ülkelerde ise yatırımların GSYİH'ye oranı ve reel GSYİH büyüme oranı gibi faktörler ön plana çıkmaktadır. Bu durum, ekonomik büyüme ve yatırım dinamiklerinin finansal istikrar üzerindeki etkisinin ülke ekonomisinin yapısal özelliklerine göre değişebileceğini göstermektedir. Bu bulgu, Levine (2005) tarafından

vurgulanan finansal gelişim ve ekonomik büyüme arasındaki ilişkiyi destekler niteliktedir. Ancak yüksek büyüme oranlarının finansal riskleri her zaman azaltmadığı, özellikle spekülatif yatırımlara dayalı büyümenin kriz olasılığını artırabileceği de unutulmamalıdır (Kindleberger, 2000). Bunlara karşın tüketici fiyatlarındaki yüzdesel değişim ve büyüme oranı, kriz dönemi tahminlerinde en az öneme sahip değişkenler olarak değerlendirilmektedir.

XGBoost sınıflandırıcısı ile gerçekleştirilen sistemik finansal kriz tahminleme çalışmalarının özellik önem derecelendirmesi sonuçları, G7 ülkelerinin ekonomik yapıları ve finansal sistemleri arasındaki farklılıkları ortaya koymaktadır. Elde edilen bulgular, ekonomik literatürdeki makine öğrenimi tabanlı finansal kriz tahmin çalışmalarıyla paralellikler göstermekte, ancak aynı zamanda bazı farklılıklar da barındırmaktadır. Bu sonuçlar, politika yapıcıların makro ihtiyati politikaları tasarlarken ve uygularken ülke özelindeki risk faktörlerini dikkate almaları gerektiğini vurgulamaktadır. Özellikle, para politikası, maliye politikası ve düzenleyici çerçeveler her ülkenin ekonomik ve finansal yapısına uygun olarak tasarlanmalıdır. Ayrıca küresel ekonomik şokların etkileri de ülke özelindeki risk faktörleri ile etkileşime girerek kriz olasılığını artırabileceği için, uluslararası iş birliği ve koordinasyon mekanizmaları da güçlendirilmelidir. Sonuç olarak sistemik finansal krizlerin önlenmesi ve yönetilmesi, ülke özelindeki risk faktörlerinin ve küresel ekonomik dinamiklerin dikkate alındığı kapsamlı ve koordineli politika yaklaşımlarını gerektirmektedir.

Sonuç olarak bu analiz G7 ülkelerinin farklı ekonomik dinamiklere sahip olduğunu ve her ülkenin krizleri önlemek için kendine özgü politikalar geliştirmesi gerektiğini ortaya koymaktadır. Bu nedenle, politika yapıcıların ülkeye özgü kırılganlıkları ve risk faktörlerini dikkate alarak proaktif ve uyarlanabilir bir yaklaşım benimsemeleri finansal istikrarın sağlanması açısından elzemdir.

3.4.3. SHAP Değerleri

Şekil 20'de G7 ülkeleri için oluşturulan SHAP (SHapley Additive exPlanations) değerleri için özet grafikler, finansal krizleri etkileyen temel faktörler hakkında ayrıntılı

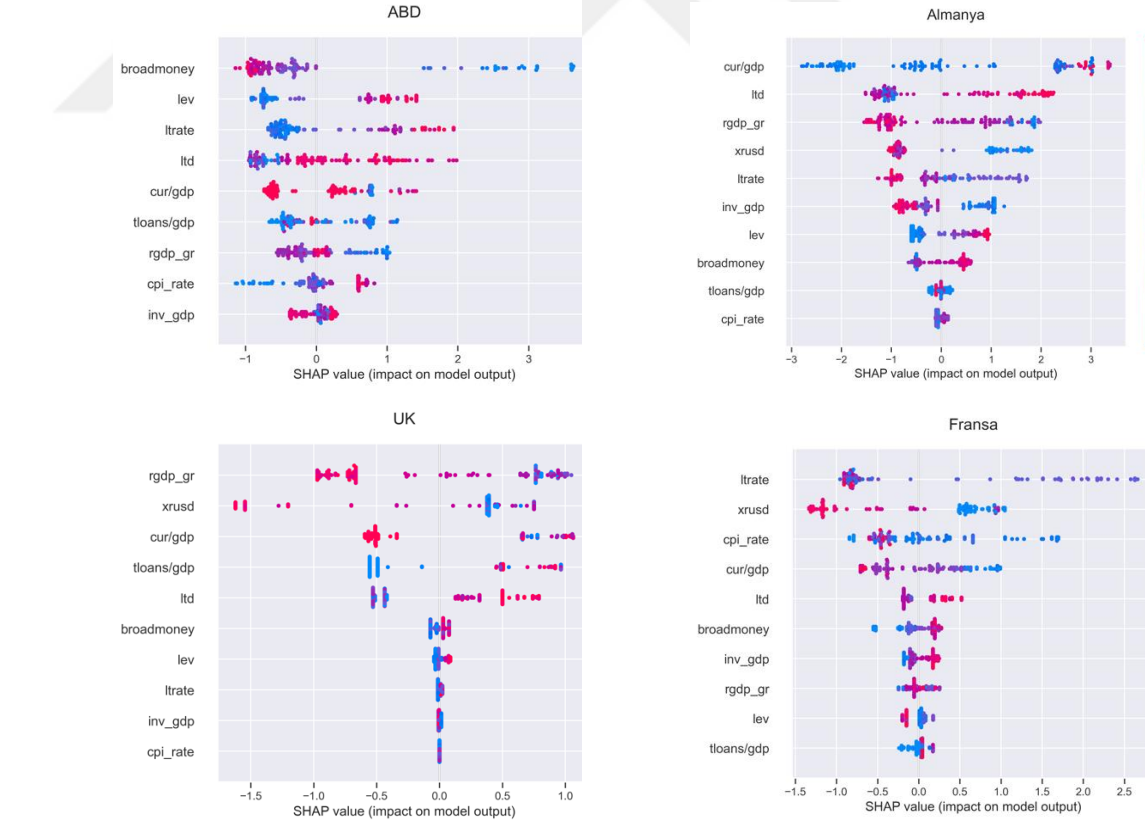
bir analiz sunarak modelin tahminlerini etkileyen değişkenlerin önemini ve yönünü detaylı bir şekilde görselleştirmektedir. Bulgular, çoğu ülkede uzun vadeli faiz oranları, para arzındaki genişleme oranı ve cari işlemler dengesinin GSYİH içindeki payının önemli belirleyiciler olduğunu ortaya koymaktadır. Söz konusu oranlardaki artışlar, modelin tahminlerini daha yüksek sistemik finansal kriz olasılıklarına doğru yönlendirme eğilimindedir.

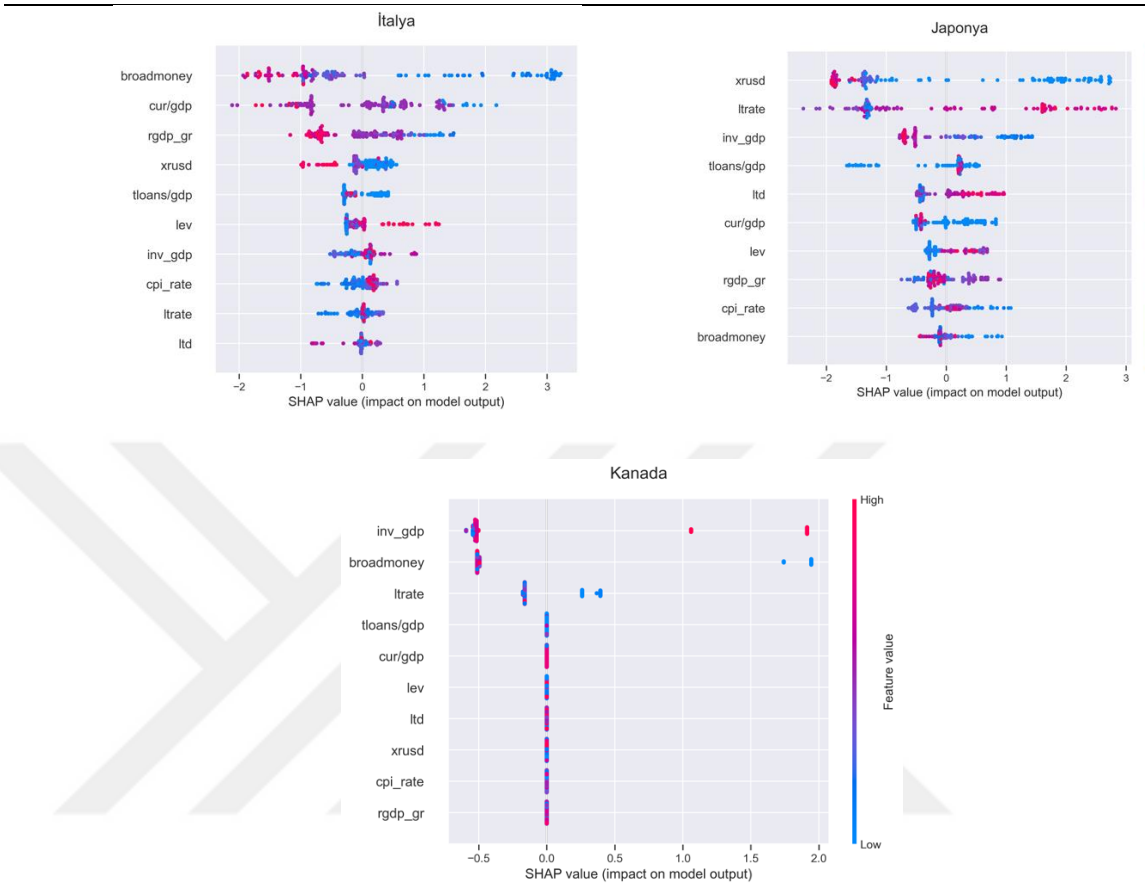
G7 ülkelerindeki sistemik finansal risklerin analizi, finansal sistemlerin istikrarını ve kırılganlığını yansıtan çeşitli ekonomik göstergeleri içermektedir. Kritik değişkenlerden biri olan para arzı, likiditenin korunması ve ekonomik istikrarın desteklenmesi için gerekli olmakla birlikte para arzının aşırı büyümesi halinde bir risk faktörü haline de gelebilir. Bankalarda kredilerin mevduata oranı (ltd) ve yine bankaların sermaye oranı (lev) bankacılık krizlerini etkileyen diğer önemli faktörlerdendir. Bu özelliklerle ilişkili yüksek SHAP değerleri, potansiyel krizlerin tespit edilmesindeki önemini vurgulamaktadır. Politika yapıcılar, finansal piyasalarda sistemik kriz habercisi olarak bu oranları aktif bir şekilde izlemelidir. Bu sonuçlar, (Bluwstein vd., 2023) çalışmalarıyla uyumlu şekilde söz konusu faktörlerin bir ülkeyi finansal krizlere karşı daha savunmasız hale getirdiğini vurgulamaktadır.

Grafik incelendiğinde ABD için geniş para arzının kontrol altında tutulması, bankacılık sektöründeki kredi/mevduat oranının sürdürülebilir seviyelerde tutulması ve uzun vadeli faiz oranlarının aşırı yükselmesini önleyecek para politikalarının uygulanması, finansal istikrarı korumak için kritik öneme sahiptir. Almanya için ihracatın teşvik edilmesi ve pozitif cari işlemler dengesinin sürdürülmesi, bankacılık sektöründeki borç seviyelerinin yakından izlenmesi ve ekonomik büyümeyi desteklemek için yatırımların artırılması, ülke ekonomisinin dayanıklılığını artırabilir. İngiltere'de ekonomik büyümeyi teşvik eden politikaların geliştirilmesi, dış ticaret açıklarının azaltılması ve bankaların kredi/mevduat oranlarının yakından takip edilmesi, İngiltere ekonomisinin kırılganlıklarını azaltmaya yardımcı olacaktır. Fransa'da enflasyonu kontrol altına almak için para politikalarının dikkatlice yönetilmesi, uzun vadeli faiz oranlarını düşük tutmak için piyasa istikrarının artırılması ve cari açığı azaltmak için üretim ve ihracatın desteklenmesi, finansal istikrarı destekleyecektir. İtalya'da para arzının dengeli

bir şekilde artırılarak likiditenin desteklenmesi, altyapı yatırımlarının artırılması ve cari işlemler dengesini geliştirmek için rekabet gücünü artırıcı adımların atılması, ülke ekonomisinin toparlanmasına katkıda bulunacaktır. Japonya'da döviz kuru istikrarını sağlamak için para politikalarının güçlendirilmesi, uzun vadeli faiz oranlarını kontrol altında tutarak borçlanma maliyetlerinin azaltılması ve yatırımları teşvik eden mali politikaların uygulanması, Japon ekonomisinin dış şoklara karşı direncini artıracaktır. Kanada için ise yatırımları artırarak ekonomik büyümenin desteklenmesi, likiditeyi artıracak ancak finansal riskleri sınırlayacak para politikalarının uygulanması ve faiz oranlarını düşük tutarak ekonomik istikrarın korunması, Kanada ekonomisinin sürdürülebilir büyümesini sağlayacağı belirtilebilir.

Şekil 20: SHAP Analizi Sonuçları



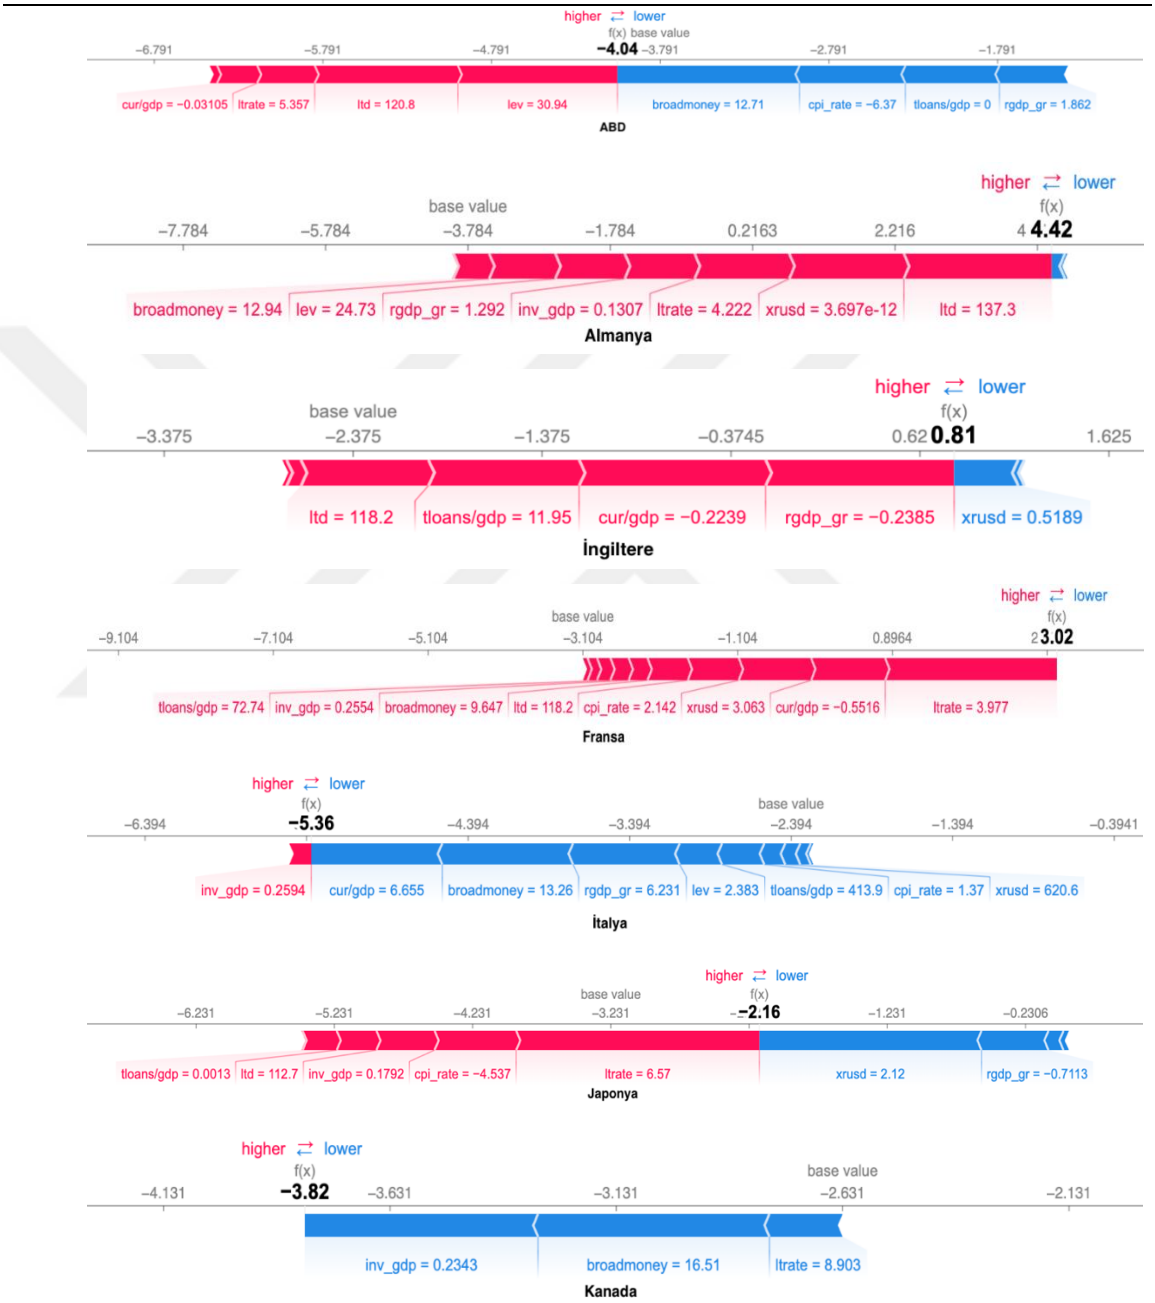


Kaynak: Yazar tarafından oluşturulmuştur.

Ülkeler arasındaki özellik farklılığı, farklı ekonomik koşulları, bankacılık ve finans piyasaları koşullarını yansıtmaktadır. Örneğin, aktif para politikalarına sahip ülkeler faiz oranlarından daha güçlü bir etki görürken, esnek kredi piyasalarına sahip olanlar kredi büyüme oranlarından daha fazla etkilenebilir. Bu bulgular, sistemik finansal krizlere yol açan durumları değiştirmek için hedeflenen politika eylemlerinin önemini vurgulamaktadır.

Şekil 21'de yer alan SHAP Force plot (Kuvvet grafiği) sonuçları, XGBoost modeli kullanılarak gerçekleştirilen sistemik finansal kriz tahminleme analizinde, belirli makroekonomik ve finansal değişkenlerin kriz olasılığı üzerindeki etkilerinin daha net bir şekilde anlaşılmasını sağlamaktadır.

Şekil 21: SHAP Force Plot Sonuçları



Kaynak: Yazar tarafından oluşturulmuştur.

Grafikte baz değer (base value) modelin sistemik finansal kriz olasılığı tahmininin başlangıç noktasıdır. Nihai tahmin f(x) ise özelliklerin pozitif ve negatif katkıları toplanarak baz değerinden hareketle hesaplanır. Kırmızı değere sahip olan değişkenler tahmini artırarak (kriz olasılığını artırma yönünde) etki ederken mavi değere sahip olan değişkenler tahmini azaltarak (kriz olasılığını düşürme yönünde) etki etmektedir.

ABD ekonomisi için XGBoost modeli ile yapılan sistemik finansal kriz tahminleme analizinde, bazı makroekonomik ve finansal değişkenlerin kriz olasılığı üzerindeki etkileri belirginleşmektedir. Cari işlemler açığının GSYİH'ye oranının düşüklüğü, uzun dönem faiz oranlarındaki artış, kredilerin mevduata oranının yüksekliği ve bankacılık kesimindeki sermaye oranının yüksekliği kriz olasılığını artıran faktörler olarak öne çıkmaktadır. Bu durum, cari dengesizliklerin, yüksek borçlanma maliyetlerinin, aşırı kredi genişlemesinin ve bankaların sermaye yapılarındaki değişimlerin finansal kırılganlığı tetikleyebileceğine işaret etmektedir. Öte yandan düşük enflasyon ve reel GSYİH büyümesi kriz olasılığını azaltan faktörler olarak tespit edilmiştir. Bu durum, likidite bolluğunun, fiyat istikrarının ve güçlü ekonomik büyümenin finansal sistemi destekleyerek sistemik riskleri azaltabileceğini göstermektedir. Finansal olmayan özel sektöre verilen kredilerin GSYİH'ye oranı ise model için anlamlı bir katkı sağlamamaktadır.

Almanya ve İngiltere için kredi piyasası ve bankacılık sektörü dinamiklerinin kriz olasılığı üzerinde baskın bir etkiye sahip olduğu görülmektedir. Kredilerin mevduata oranındaki yüksek seviyeler ve bankaların sermaye oranındaki artış, sistemik riskin en önemli göstergeleri olarak öne çıkmaktadır. Bu durum, aşırı kredi genişlemesinin ve bankacılık sektöründeki potansiyel kırılganlıkların finansal istikrarı tehdit edebileceğine işaret etmektedir. Bu analiz, Almanya'da politika yapıcıların özellikle bankacılık sektörünü yakından izlemesi ve kredi piyasasının sürdürülebilirliğini sağlamak için makro ihtiyati tedbirler alması gerektiğini vurgulamaktadır. İngiltere'de USD döviz kurunun kriz olasılığını azaltıcı etkisi ise döviz kurunun istikrarının ekonomik güveni destekleyebileceğine işaret etmektedir.

Fransa ekonomisi için XGBoost sınıflandırıcısı ile yapılan sistemik finansal kriz tahminleme analizinde, özel sektör borçlanmasının yüksekliği ve bankacılık sektöründeki

bazı göstergelerin kriz olasılığı üzerinde önemli bir etkiye sahip olduğu görülmektedir. Grafik üzerinde negatif katkı sağlayan faktörlerin bulunmaması ise Fransa ekonomisinin krizlere karşı daha az dirençli olabileceğine işaret etmektedir.

Model İtalya'nın ekonomik istikrarını destekleyen çeşitli faktörlere ağırlık vermektedir. Cari işlemler hesabının GSYİH'ye oranının yüksekliği ve devamındaki değişkenler kriz olasılığını azaltan en önemli faktörler olarak öne çıkmaktadır. Japonya ekonomisinde ise bankacılık sektöründeki likidite risklerinin kriz olasılığı üzerindeki etkileri öne çıkmaktadır. Döviz kurunun ve büyüme oranının kriz olasılığını azaltması ise Japonya'da ekonomik büyümenin istikrarı desteklediğini göstermektedir.

Kanada ekonomisi için XGBoost sınıflandırıcısı ile yapılan sistemik finansal kriz tahminleme analizinde, ülkenin genel olarak düşük bir kriz riski taşıdığı görülmektedir. Model, analizde kullanılan tüm değişkenlerin kriz olasılığını azaltıcı yönde etki ettiğini göstermektedir. Yatırımın GSYİH'ye oranı (inv_gdp), geniş para arzındaki büyüme (broadmoney) ve uzun dönem vadeli faiz oranları (rate) kriz olasılığını azaltan faktörler olarak öne çıkmaktadır. Bu durum, Kanada ekonomisinin yatırım, likidite ve faiz oranları açısından istikrarlı bir durumda olduğunu ve bu faktörlerin finansal istikrarı desteklediğini göstermektedir.

Analiz, Kanada'da politika yapıcıların ekonomik istikrarı korumaya, yatırımları teşvik etmeye, likiditeyi desteklemeye ve faiz oranlarını istikrarlı bir seviyede tutmaya odaklanması gerektiğini vurgulamaktadır. Genel olarak Kanada ekonomisinin mevcut durumu dikkate alındığında, sistemik finansal kriz olasılığı düşük seviyelerde seyretmektedir ve mevcut politikaların finansal istikrarı desteklemeye devam ettiği söylenebilir.

G7 ülkelerinin ekonomik istikrarını güçlendirmek ve ortak riskleri azaltmak için kapsamlı bir politika seti uygulanması gerekmektedir. Finansal sistemin direnci için bankaların sermaye yeterliliğinin artırılması ve kredi/mevduat oranlarının sürdürülebilir düzeylerde tutulması kritik öneme sahiptir. Para politikası, fiyat istikrarını hedefleyerek ve ekonomik büyümeyi destekleyici faiz oranları aracılığıyla makroekonomik dengeyi sağlamalıdır. Özel sektör yatırımlarını teşvik eden mali teşvikler ve büyüme odaklı reformlar reel büyüme oranlarını yükseltmelidir. Dış ticaret açıklarını azaltmaya yönelik

politikalar ve ihracatın artırılması yoluyla cari açığın kontrol altına alınması, dış finansman ihtiyacını düşürerek ekonomik kırılganlığı azaltacaktır. Bu bütüncül strateji, G7 ülkelerinin küresel ekonomik liderliğini sürdürmesine ve refahını artırmasına olanak tanıyacaktır.

3.5. SONUÇ

Finansal sistemlerin kırılganlığının tespiti, finansal krizlerin sosyoekonomik sonuçları göz önüne alındığında büyük önem arz etmektedir. Çünkü kırılgan bir sistem, dış şokları geniş çaplı bir krize dönüştürebilme potansiyeline sahiptir. Bu bağlamda, finansal krizlerin erken dönemde belirlenmesi, politika yapıcıların proaktif önlemler alarak olumsuz etkileri minimize etmesine olanak tanırken, erken uyarı sistemlerinin geliştirilmesi veri sınırlamaları, gecikmeli sinyaller ve model karmaşıklığı gibi zorlukları da beraberinde getirmektedir.

Bu çalışmada G7 ülkeleri için XGBoost sınıflandırıcısı ile yapılan sistemik finansal kriz tahminleme analizlerinin SHAP özet grafiklerine dayalı ekonomik politika önerileri, ülkelerin özgün risk profillerini ve ortak eğilimlerini dikkate alan stratejik bir çerçeve sunmaktadır. Çalışmanın bulguları, G7 ülkelerinin kriz dönemlerinin etkilerini en aza indirmek amacıyla etkili para ve maliye politikası araçları geliştirmesi gerektiğini göstermektedir. Bu bağlamda, ABD Merkez Bankası (FED) ve diğer düzenleyici kurumlar, finansal şoklara karşı hızlı ve etkin bir şekilde yanıt verebilmelidir. G7 ülkelerinde makro ihtiyati politikalardan sorumlu ulusal ve uluslararası otoriteler, ilgili ülkeler için makro ihtiyati politika duruşunu belirlerken muhakemelerini kullanmalıdır. Bu süreçte, bu çalışmada önerilen XGBoost yöntemi ve SHAP değerleri gibi araçlar çeşitli amaçlara hizmet edebilir. Geçmişte sistemik bankacılık krizlerine yol açan risklerin ortaya çıkması durumunda, makro ihtiyati politika araçlarının neden devreye sokulmadığını yalnızca muhakemeye dayanarak açıklamak zorlaşabilir. Dolayısıyla, bu tür analitik modellerin güçlü performansı, politika yapıcıların bu tür durumlarda kararlarının gerekçesini daha sağlam temellere dayandırmalarını sağlamaktadır. Ayrıca XGBoost yönteminin sezgisel yapısı ve kolay görselleştirilmesi, politika tartışmaları için bir

başlangıç noktası olarak analitik bir yaklaşımın benimsenmesini teşvik edebilir. Son olarak bu yöntemin bir diğer avantajı, belirli bir kriz olasılığı ile ilişkilendirilen özelliklere bağlı olarak kırılganlığın niteliğinin de belirlenebilmesidir. Bu, belirli bir politika aracının diğerine göre daha uygun olduğu yönünde önerilerde bulunulmasına olanak tanıyacaktır.

Gelecekteki araştırmalar, sistemik bankacılık krizlerinin ülkeler arasındaki finansal ve ekonomik aktörler üzerindeki yayılma etkilerini hem finansal hem de ticari bağlantıları dikkate alarak detaylı bir şekilde inceleyebilir. Sistemik bankacılık krizlerinin temel nedenlerinin ve uluslararası politika bütünlüğünün söz konusu krizlerin küresel istikrar üzerindeki etkilerini azaltmadaki rolünün araştırılması da alana önemli katkılar sağlayacaktır. Sonuç olarak makro ihtiyati politikaların tasarımı ve uygulanması, ülke özelindeki risk faktörlerinin ve küresel ekonomik dinamiklerin dikkate alındığı bütüncül bir yaklaşımla gerçekleştirilmelidir. Makine öğrenimi modellerinin sunduğu öngörü yeteneği, politika yapıcıların erken uyarı sistemlerini geliştirmelerine ve proaktif önlemler almalarına yardımcı olabilir.

SONUÇ VE ÖNERİLER

Finansal balonlar, aşırı iyimserlik ve spekülasyonun etkisiyle varlık fiyatlarının temel değerlerinden uzaklaşması durumudur. Bu durum, finansal sistemde kırılganlıklar oluşturarak balonun patlamasıyla finansal krizlere zemin hazırlayabilir. Krizler, balonların yarattığı dengesizlikleri düzeltici bir mekanizma olarak işlev görse de ekonomik aktivite üzerinde kalıcı olumsuz etkilere neden olabilir. Dolayısıyla, finansal istikrarın korunması ve ekonomik krizlerin önlenmesi için finansal balonların erken tespiti ve yönetimi kritik öneme sahiptir.

Sonuç olarak hem pozitif hem de negatif finansal balonların tespiti, finansal krizler için değerli erken uyarı sinyalleri olarak kabul edilebilir. Ancak, balonların tespiti zorlu bir süreçtir ve çeşitli yöntemler (örneğin, ekonometrik modeller, makine öğrenmesi algoritmaları, piyasa göstergeleri) kullanılarak yapılabilir. Erken uyarı sinyallerinin doğru yorumlanması ve uygun politika tepkilerinin verilmesi ise finansal istikrarın sağlanması ve ekonomik krizlerin önlenmesi açısından kritik öneme sahiptir.

Bu tez çalışmasının temel amacı, finansal balonların ve krizlerin makine öğrenmesi yöntemleriyle erken tespiti için yüksek performanslı erken uyarı sistemleri geliştirilmesine ve bu sistemlerin etkinliğinin değerlendirilmesine odaklanmaktadır. Bu amaç doğrultusunda finansal balonları ve finansal krizleri temel alan üç özgün makale çalışması gerçekleştirilmiştir. Araştırmalarda, ilk olarak Türkiye özelinde balon ve kriz dinamikleri incelenmiş, ardından kapsamı G7 ülkelerini içerecek şekilde genişletilmiştir.

Çalışmanın birinci bölümünde, Borsa İstanbul'da yer alan önemli indekslerden olan BİST 100, BİST Banka ve BİST Sınai endekslerindeki balon dönemleri, zaman serilerinde gözlemlenen yapısal değişimler ile volatilite seviyelerindeki farklılıkları dikkate alan GSADF yöntemiyle tespit edilmiştir. Ardından, balon oluşumu ile makroekonomik değişkenler arasındaki etkileşim dikkate alınarak rassal orman algoritması aracılığıyla tahminleme gerçekleştirilmiştir. Analiz sonuçlarına göre Türkiye'de XU100, XBANK ve XUSIN endekslerindeki fiyat balonlarının oluşumuna etki eden başlıca faktörlerin; para arzı, döviz kuru hareketleri, tüketici fiyat endeksi, ABD Merkez Bankası faiz politikaları ve bileşik öncü göstergeler endeksi olduğu sonucuna

ulaşılmıştır. Bu doğrultuda, finansal piyasalarda balon risklerinin azaltılması ve makroekonomik istikrarın sağlanabilmesi açısından para politikası araçları ile makro-ihtiyati önlemlerin zamanında ve etkili biçimde uygulanmasının gerekliliği ortaya konulmaktadır. Ayrıca, makine öğrenmesine dayalı yöntemlerin finansal balonları erken evrede belirlemesi ve sistemik risklerin yönetimi konusunda kayda değer bir potansiyel taşıdığı sonucuna ulaşılmıştır. Modelin tahmin performansına ilişkin bulgular, önerilen yöntemin yüksek doğruluk oranına sahip olduğunu ve finansal balonların öngörüsünde uygulanabilir bir alternatif oluşturabileceğini göstermektedir.

İkinci bölümde Türkiye ekonomisi için finansal krizlerin erken tespitine yönelik olarak uluslararası rezervler, döviz kuru ve faiz oranları kullanılarak oluşturulan finansal baskı endeksi ile finansal kriz dönemleri tespit edilmiş ve Türkiye ekonomisine ait makroekonomik ve finansal göstergeler 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.

Türkiye için yapılan analiz sonuçlarına göre her iki çalışma da finansal istikrarsızlığın iki kritik ve sıklıkla birbiriyle ilişkili tezahürü olan finansal balonlar ve finansal krizler üzerine odaklanmaktadır. Her iki olgunun tespiti ve tahmini için ekonometrik testlerin yanı sıra makine öğrenmesi başarılı bir şekilde uygulanarak bütünleşik bir yaklaşım benimsenmiştir. BİST endekslerinde dönemsel finansal balonların varlığı tespit edilmiş; bu durum, ilgili dönemlerde piyasa etkinliğinin zayıfladığına ve varlık fiyatlarının temel değerlerinden saptığına işaret etmektedir. Rassal orman modeli, merkez bankası politikaları kapsamındaki makroekonomik ve finansal göstergelerdeki değişimlerin bu balonları tetiklemedeki rolünü ortaya koymuş ve erken uyarı sinyalleri üretebilme potansiyelini göstermiştir. Finansal balonların patlamasıyla da tetiklenebilen finansal krizlerin analizi ise, Türkiye ekonomisi için finansal krizleri öngörmede yüksek başarı sergileyen bütçe açıklarıyla ilişkili parasal göstergeler, döviz kuru dinamikleri gibi öncü makroekonomik ve finansal göstergeleri belirlemiştir. Özellikle, belirlenen bu öncü göstergelerin, birinci nesil kriz modellerinin Krugman (1979) teorik çerçevesiyle önemli

ölçüde uyum göstermesi dikkat çekicidir. Analiz dönemi itibarıyla Türk lirasının reel dış değerindeki belirgin istikrarsızlık hem teorik beklentileri hem de kriz dinamiklerini destekleyen önemli bir ampirik bulgu olarak öne çıkmaktadır. Gerek balonlar gerekse krizler için, belirlenen göstergelerin kısmi bağımlılık grafikleri dikkate alınarak belirlenen kritik eşik değerlerinin erken uyarı sistemlerinin (EWS) geliştirilmesinde kullanılabileceğini teyit etmektedir. Makine öğrenmesi yöntemlerinin karmaşık ve doğrusal olmayan ilişkileri modellemedeki başarısı, bu tür EWS'lerin performansını geleneksel yöntemlere kıyasla artırma potansiyeli taşımaktadır. Bu bulgular ışığında, Türkiye ekonomisinin finansal şoklara karşı direncini artırmak için fiyat istikrarı ve döviz kuru istikrarını merkeze alan proaktif politikalara ve dış finansman bağımlılığını azaltacak yapısal reformlara duyulan ihtiyaç açıktır. Sonuç olarak balon ve kriz dinamiklerinin makine öğrenmesi destekli bütünleşik analizi, Türkiye'deki finansal risklerin daha iyi anlaşılmasına, öngörülmesine ve yönetilmesine yönelik değerli ve uygulanabilir bir çerçeve sunmaktadır.

Çalışmanın üçüncü bölümünde ise G7 ülkelerine ait finansal ve makroekonomik veriler kullanılarak sistemik bankacılık kriz tahmininde XGBoost tabanlı bir model geliştirilmiştir. Modelin karar alma süreçlerini anlamlandırmak amacıyla SHAP (SHapley Additive exPlanations) yöntemleri uygulanarak model sonuçları arasındaki nedensel ilişkiler analiz edilmiştir. Analiz sonuçlarına göre G7 ülkelerinin ekonomik istikrarını güçlendirmek ve ortak riskleri azaltmak için kapsamlı bir politika seti uygulanması gerekmektedir. Finansal sistemin direnci için bankaların sermaye yeterliliğinin artırılması ve kredi/mevduat oranlarının sürdürülebilir düzeylerde tutulması kritik öneme sahiptir. Para politikası, fiyat istikrarını hedefleyerek ve ekonomik büyümeyi destekleyici faiz oranları aracılığıyla makroekonomik dengeyi sağlamalıdır. Özel sektör yatırımlarını teşvik eden mali teşvikler ve büyüme odaklı reformlar reel büyüme oranlarını yükseltmelidir. Dış ticaret açıklarını azaltmaya yönelik politikalar ve ihracatın artırılması yoluyla cari açığın kontrol altına alınması, dış finansman ihtiyacını düşürerek ekonomik kırılganlığı azaltacaktır. Bu bütüncül strateji, G7 ülkelerinin küresel ekonomik liderliğini sürdürmesine ve refahını artırmasına olanak tanıyacaktır.

Aynı zamanda, G7 ülkelerinin kriz dönemlerinin etkilerini en aza indirmek amacıyla etkili para ve maliye politikası araçları geliştirmesi gerektiğini göstermektedir. Bu bağlamda, ABD Merkez Bankası (FED) ve diğer düzenleyici kurumlar, finansal şoklara karşı hızlı ve etkin bir şekilde yanıt verebilmelidir. G7 ülkelerinde makro ihtiyati politikalardan sorumlu ulusal ve uluslararası otoriteler, ilgili ülkeler için makro ihtiyati politika duruşunu belirlerken muhakemelerini kullanmalıdır. Bulgular, XGBoost'un yüksek tahmin performansı sergileyerek uygulayıcılar ve politika yapıcılar için kriz riskini değerlendirmede yeni olanaklar sunduğunu göstermektedir. Ek olarak SHAP değerleri, tahmin edici değişkenler ile kriz riski arasındaki karmaşık ilişkileri ortaya çıkararak makine öğrenimi modellerinin şeffaflığını ve hesap verebilirliğini önemli ölçüde artırmaktadır. Bu yaklaşım, finansal krizlerin temel ekonomik itici güçlerini belirleme konusunda güvenilir bir altyapı sunarak politika tercihlerinin daha kapsamlı bir karar alma sürecine dahil edilmesine olanak tanımaktadır.

Doktora tezi kapsamında yapılan çalışmaların genel bir sonucu olarak üç ayrı çalışmanın da ulaştığı ortak sonuç, finansal balonlar ve krizler gibi karmaşık, doğrusal olmayan ve yüksek maliyetli olguların tahminlenmesinde makine öğrenmesi yöntemlerinin yüksek bir etkinlik ve potansiyel sergilediğidir. Gerek Türkiye özelinde finansal balon ve krizler için gerekse G7 ülkeleri bağlamında sistemik bankacılık krizleri için rassal orman ve XGBoost gibi farklı makine öğrenmesi algoritmaları, finansal istikrarsızlık dinamiklerini başarıyla modelleyebilmiş ve yüksek tahmin performansı göstermiştir. Tüm çalışmalar, finansal istikrarsızlığın erken tespiti amacıyla kritik öneme sahip makroekonomik ve finansal öncü göstergelerin belirlenmesinin ve bu göstergelerdeki kritik değişimlerin takip edilmesinin gerekliliğini teyit etmektedir. Bu bulgular hem gelişmekte olan hem de gelişmiş ekonomiler için daha güvenilir ve zamanlı EWS geliştirilmesine sağlam bir analitik zemin sunmaktadır. Ayrıca, G7 çalışmasında kullanılan SHAP gibi açıklanabilirlik yöntemleri, bu gelişmiş modellerin "kara kutu" özelliğini azaltarak karar alma süreçlerinin şeffaflığını ve sonuçların yorumlanabilirliğini artırmanın mümkün olduğunu göstermiştir. Bu şeffaflık, geliştirilen modellerin politika yapıcılar tarafından anlaşılması, benimsenmesi ve gerekçelendirilmiş kararlar alınmasında etkin bir şekilde kullanılması açısından büyük önem taşımaktadır.

Dolayısıyla, üç çalışmanın kolektif bulguları, makine öğrenmesi destekli analitik yaklaşımların, finansal risklerin proaktif yönetimi, finansal istikrarı sağlamaya yönelik politika müdahalelerinin (makro ihtiyati, para ve maliye politikaları dahil) tasarımı ve uygulanması için güçlü ve değerli araçlar sunduğunu ortaya koymaktadır.

Yapılan çalışmaların literatüre ortak katkısı, öncelikle finansal balonlar ve krizler gibi finansal istikrarsızlığın farklı tezahürlerinin tespiti ve özellikle tahmini konusunda modern makine öğrenmesi yöntemlerinin (rassal orman, XGBoost) etkinliğini ve uygulanabilirliğini Türkiye ve G7 ülkeleri gibi farklı ekonomik bağlamlarda göstermesidir. Her üç makale de kendi odaklandığı alanda, geleneksel yaklaşımlara kıyasla bu gelişmiş algoritmaların potansiyel metodolojik üstünlüklerinden yararlanarak ampirik analizlere derinlik katmaktadır. Çalışmalar, finansal istikrarsızlık olaylarını tetikleyen veya öngören temel makroekonomik ve finansal göstergelerin belirlenmesi ve bu ilişkilerin nicel olarak modellenmesi açısından önemli bulgular sunmaktadır. Ayrıca, Türkiye özelinde FBE gibi mevcut araçların güncel verilerle ve yeni yöntemlerle (rassal orman) yeniden ele alınmasıyla literatüre güncel bir perspektif kazandırılmıştır. Metodolojik sağlamlığa verilen önem, özellikle finansal verilerde yaygın olan dengesiz veri kümeleri sorununa yönelik uygun tekniklerin kullanılması ve modellerin titiz doğrulama süreçleriyle geçerliliğinin sınanması yoluyla da ortak bir katkı olarak öne çıkmaktadır. G7 çalışması özelinde SHAP analizlerinin kullanılmasıyla makine öğrenmesi modellerinin yorumlanabilirliğinin artırılması, bu tekniklerin sadece tahmin başarısı değil, aynı zamanda politika yapımı için şeffaflık ve anlaşılabilirlik sunma potansiyelini de vurgulayarak önemli bir literatür boşluğunu doldurmaktadır. Bu sayede, geliştirilen modellerin sadece akademik değil, pratik uygulamalarda da kullanılabilirliği desteklenmektedir. Sonuç olarak bu tezdeki çalışmalar kolektif biçimde, makine öğrenmesinin finansal istikrarsızlık çalışmalarında hem tahmin gücünü artıran hem de altta yatan dinamiklerin anlaşılmasına yardımcı olan güçlü bir analitik çerçeve sunduğunu ortaya koymaktadır.

Yapılan çalışma sonuçlarına göre gelecekteki çalışmalar için öneriler, finansal balonların ve krizlerin tespiti ile tahminlenmesine yönelik erken uyarı sistemlerinin farklı veri kaynakları ve gelişmiş makine öğrenmesi algoritmaları entegre edilerek geliştirilmesi

gerektiğini ortaya koymaktadır. Ayrıca, finansal krizlerin ülkeler arası yayılım etkileri, temel nedenleri ve küresel dinamiklerin rolü gibi konularda derinlemesine analizler yapılması önerilmektedir. Elde edilen ampirik bulguların ışığında, potansiyel riskleri azaltmak ve makroekonomik maliyetleri hafifletmek amacıyla etkin politika müdahaleleri ve proaktif makro ihtiyati düzenlemelerin tasarlanması ve uygulanması büyük önem taşımaktadır. Bu bağlamda, makine öğrenmesi modellerinin sunduğu öngörü yeteneği, politika yapıcılar için değerli bir araç olarak öne çıkmaktadır. Çalışmalar, hem ülke özelindeki risk faktörlerini hem de küresel ekonomik dinamikleri dikkate alan bütüncül yaklaşımların gerekliliğini vurgulamaktadır.

KAYNAKÇA

Aikman, D., Galesic, M., Gigerenzer, G., Kapadia, S., Katsikopoulos, K., Kothiyal, A., Murph, & y, E. ve Neumann, T. (2021). Taking uncertainty seriously: Simplicity versus complexity in financial regulation. *Industrial and Corporate Change*, 30(2), 317-345.

Aizenman, J. ve 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.

Aka, K. (2020). Seçilmiş makroekonomik göstergelerin döviz kuru üzerinde etkisi: Türkiye ekonomisi üzerine bir uygulama. *BDDK Bankacılık ve Finansal Piyasalar Dergisi*, *14*(1), 99-117.

Akçalı, B. Y. (2015). MIST Ülkeleri Finansal Baskı Endeksleri (FBE)nin Yapay Sinir Ağları ve Box-Jenkıns Yöntemleriyle Tahmin Edilerek Finansal Krizlerin Öngörülmesi. *Muhasebe Bilim Dünyası Dergisi*, 17(2), 347-384.

Akinci, O. ve Olmstead-Rumsey, J. (2018). How effective are macroprudential policies? An empirical investigation. *Journal of Financial Intermediation*, 33, 33-57.

Akkaya, M. (2018). Borsa İstanbul hisse senedi getirilerinde balon oluşumu üzerine bir uygulama. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*.

Aksoy, N. ve Genc, I. (2023). Predictive models development using gradient boosting based methods for solar power plants. *Journal of Computational Science*, 67, 101958.

Alessi, L. ve Detken, C. (2018). Identifying excessive credit growth and leverage. *Journal of financial stability*, *35*, 215-225.

Allen, F. ve Gale, D. (2009). *Understanding financial crises*. Oxford University Press.

Altıntaş, H. ve 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. ve 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. ve 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.

Astill, S., Harvey, D. I., Leybourne, S. J. ve Taylor, A. R. (2017). Tests for an end-of-sample bubble in financial time series. *Econometric Reviews*, *36*(6-9), 651-666.

Avcı, M. A. ve 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. ve 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. ve 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.

Babecký, J., Havránek, T., Matějů, J., Rusnák, M., Šmídková, K. ve Vašíček, B. (2014). Banking, debt, and currency crises in developed countries: Stylized facts and early warning indicators. *Journal of Financial Stability*, 15, 1-17.

Başoğlu Kabran, F. ve Ünlü, K. D. (2021). A two-step machine learning approach to predict S&P 500 bubbles. *Journal of Applied Statistics*, *48*(13-15), 2776-2794.

Bayram Arlı, N., Barca, O. ve Görentaş, M. B. (2022). Rassal Orman. Bayram Arlı, N., Gürsakal, S. & Engin, M. (Der.), Denetimli Makine Öğrenmesi Algoritmaları (119-148). Ankara: Nobel Yayıncılık.

Berg, A. ve Pattillo, C. (1999). *Are Currency Crises Predictable? A Test*. IMF Staff Papers, 46(2), 107-138.

Beutel, J., List, S. ve 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. ve 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. (2001). Random forests. *Machine learning*, *45*, 5-32.

Breiman, L., Friedman, J. H., Olshen, R. A. ve Stone, C. J. (1984). *Classification and regression trees.* Wadsworth and Brooks, Monterey, CA.

Brunnermeier, M. K. (2009). Deciphering the liquidity and credit crunch 2007–2008. *Journal of Economic Perspectives*, 23(1), 77-100.

Brunnermeier, M. K. (2016). Bubbles. In *Banking Crises: Perspectives from The New Palgrave Dictionary* (pp. 28-36). London: Palgrave Macmillan UK. https://doi.org/10.1057/9781137553799_5.

Brunnermeier, M. K. ve Oehmke, M. (2013). Chapter 18—Bubbles, Financial Crises, and Systemic Risk. İçinde G. M. Constantinides, M. Harris ve R. M. Stulz (Ed.), *Handbook of the Economics of Finance* (C. 2, ss. 1221-1288). Elsevier.

Calvo, G. A. ve Reinhart, C. M. (2002). Fear of floating. *The Quarterly journal of economics*, *117*(2), 379-408.

Calvo, G. A., Leiderman, L. ve Reinhart, C. M. (1996). Inflows of Capital to Developing Countries in the 1990s. *Journal of economic perspectives*, *10*(2), 123-139.

Cardarelli, R., Elekdag, S. ve Lall, S. (2011). Financial stress and economic contractions. *Journal of Financial Stability*, 7(2), 78-97. https://doi.org/10.1016/j.jfs.2010.01.005

Casabianca, E. J., Catalano, M., Forni, L., Giarda, E. ve 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.

Case, K. E. ve Shiller, R. J. (2003). Is there a bubble in the housing market?. *Brookings papers on economic activity*, *2003*(2), 299-362.

Caspi, I. (2017). Rtadf: Testing for bubbles with EViews. *Journal of Statistical Software*, *81*, 1-16. https://doi.org/10.18637/jss.v081.c01

Catao, L. A. ve Terrones, M. E. (2005). Fiscal deficits and inflation. *Journal of Monetary Economics, 52*(3), 529-554.

Chang, T., Aye, G. C. ve Gupta, R. (2014). Testing for multiple bubbles in the BRICS stock markets. *University of Pretoria Department of Economics Working Paper Series*, *7*.

Chatzis, S. P., Siakoulis, V., Petropoulos, A., Stavroulakis, E. ve Vlachogiannakis, N. (2018). Forecasting stock market crisis events using deep and statistical machine learning techniques. *Expert Systems with Applications*, 112, 353-371.

Chawla, N. V., Bowyer, K. W., Hall, L. O. ve Kegelmeyer, W. P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*, 16, 321-357.

Chen, S., Huang, Y. ve Ge, L. (2024). An early warning system for financial crises: A temporal convolutional network approach. *Technological and Economic Development of Economy*, 30(3), Article 3.

Cutler, A., Cutler, D. R. ve Stevens, J. R. (2012). Random forests. *Ensemble machine learning: Methods and applications*, 157-175.

Çağlayan Akay, E. (2020). Ekonometride büyük veri ve makine öğrenmesi: Temel kavramlar. AVESİS. https://avesis.marmara.edu.tr/yayin/609c108f-c897-4877-a16c-cddb401d46f5/ekonometride-buyuk-veri-ve-makine-ogrenmesi-temel-kavramlar

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. ve Önder, A. Ö. (2008). Determinants of currency crises in emerging markets: The case of Turkey. *Emerging Markets Finance and Trade*, *44*(5), 54-67.

Dabrowski, J. J., Beyers, C. ve de Villiers, J. P. (2016). Systemic banking crisis early warning systems using dynamic Bayesian networks. *Expert Systems with Applications*, 62, 225-242.

Davis, E. P. ve 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. ve Detragiache, E. (1998). *Financial liberalization and financial fragility* (No. 1917). World Bank Publications.

Deperlioğlu, Ö. ve Köse, U. (2024). Python ile makine öğrenmesi. Ankara: Seçkin Yayıncılık,

Dhaliwal, S. S., Nahid, A.-A. ve Abbas, R. (2018). Effective Intrusion Detection System Using XGBoost. *Information*, 9(7), 149.

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. ve 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. ve 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. ve 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. ve Végh, C. A. (2002). Modern hyper-and high inflations. *Journal of Economic literature*, *40*(3), 837-880.

Frankel, J. A. ve Rose, A. K. (1996). Currency crashes in emerging markets: An empirical treatment. *Journal of international Economics*, *41*(3-4), 351-366.

Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5), 1189-1232. https://www.jstor.org/stable/2699986

Genuer, R., Poggi, J. M. ve Tuleau-Malot, C. (2010). Variable selection using random forests. *Pattern recognition letters*, *31*(14), 2225-2236.

Giannellis, N. ve Tzanaki, M. A. (2025). Macroeconomic responses to financial stress shocks: Evidence from the US and the Eurozone. *International Economics*, *181*, 100573.

Giese, J., Nelson, B., Tanaka, M. ve Tarashev, N. A. (2013). How Could Macroprudential Policy Affect Financial System Resilience and Credit? Lessons from the Literature. *SSRN Electronic Journal*.

Gilles, C. ve LeRoy, S. F. (1992). Asset price bubbles. *The New Palgrave Dictionary of Money and Finance*. Macmillan Reference, London.

Goldstein, M. ve Turner, P. (1998). Banking crises in emerging economies: origins and policy options. *Available at SSRN 52074*.

Greenwood, R., Hanson, S. G., Shleifer, A. ve Sørensen, J. A. (2022). Predictable financial crises. *The Journal of Finance, 77*(2), 863-921.

He, Y., Lu, X., Fournier-Viger, P. ve Huang, J. Z. (2024). A novel overlapping minimization SMOTE algorithm for imbalanced classification. *Frontiers of Information Technology & Electronic Engineering*, 25(9), 1266-1281.

Hennequin, M. ve Hommes, C. (2023). Managing bubbles in experimental asset markets with monetary policy. *Journal of Money Credit and Banking*, 56(2-3), 429-454. https://doi.org/10.1111/jmcb.13050

Hoggarth, G., Reis, R. ve Saporta, V. (2002). Costs of banking system instability: Some empirical evidence. *Journal of Banking & Finance*, 26(5), 825-855.

Holopainen, M. ve Sarlin, P. (2017). Toward robust early-warning models: A horse race, ensembles and model uncertainty. *Quantitative Finance*, *17*(12), 1933-1963.

Hoque, K. ve Aljamaan, H. (2021). Impact of hyperparameter tuning on machine learning models in stock price forecasting. *IEEE Access*, 9, 163815-163830. https://doi.org/10.1109/access.2021.3134138

Huang, C., Simpson, S., Ulybina, D. ve Roitman, A. (2019). *News-based sentiment indicators*. International Monetary Fund.

Ishrakieh, L. M., Dagher, L. ve 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

James, G., Witten, D., Hastie, T. ve Tibshirani, R. (2013). An introduction to statistical learning (Vol. 112, p. 18). New York: Springer.

Jeanne, O. ve 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.

Ji, M., Dou, Z., Li, H. ve Wang, M. (2021). Multi-characteristic product price research based on gsadf-bp model. *IEEE Access*, 9, 166870-166885. https://doi.org/10.1109/access.2021.3132726

Jordà, Ò., Schularick, M. ve Taylor, A. M. (2011). Financial Crises, Credit Booms, and External Imbalances: 140 Years of Lessons. *IMF Economic Review*, 59(2), 340-378.

Kaminsky, G. L. ve 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. ve 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. ve 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. ve ÇIRPICI, Y. A. (2024). Türkiye'de Finansal Krizlerin Öngörülebilirliği: YSA Tabanlı Erken Uyarı Sistemi. *Ekonomik Yaklaşım, 35*(130).

Kauko, K. (2014). How to foresee banking crises? A survey of the empirical literature. *Economic Systems,* 38(3), 289-308.

Kaya, V. ve 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 Scriblerian and the Kit-Cats, 32*(2), 379.

Koç Ustalı, N., Tosun, N. ve Tosun, Ö. (2021). Makine öğrenmesi teknikleri ile hisse senedi fiyat tahmini. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 16(1), 1-16. https://doi.org/10.17153/oguiibf.636017

Korkmaz, Ö., Erer, D. ve Erer, E. (2016). Alternatif yatırım araçlarında ortaya çıkan balonlar Türkiye hisse senedi piyasasını etkiliyor mu? BİST 100 üzerine bir uygulama. *BDDK Bankacılık ve Finansal Piyasalar,* 10(2), 29-61.

Krugman, P. (1979). A model of balance-of-payments crises. *Journal of money, credit and banking*, *11*(3), 311-325.

Laeven, M. L. ve Valencia, M. F. (2012). *Systemic Banking Crises Database: An Update*. International Monetary Fund.

Laeven, M. L. ve Valencia, M. F. (2018). *Systemic Banking Crises Revisited*. International Monetary Fund.

García, E. M., Pavlidis, E., & Vasilopoulos, K. (2021). exuber: Recursive Right-Tailed Unit Root Testing with R. Federal Reserve Bank of Dallas, *Globalization Institute Working Papers*, 2020(383). https://doi.org/10.24149/gwp383r1

Lane, P. R. ve 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. ve Wang, R. (2020). Bootstrap aggregating and random forest. *Macroeconomic forecasting in the era of big data: Theory and practice*, 389-429.

Levine, R. (2005). Chapter 12 Finance and Growth: Theory and Evidence. İçinde P. Aghion & S. N. Durlauf (Ed.), *Handbook of Economic Growth* (C. 1, ss. 865-934). Elsevier.

Liaw, A. ve Wiener, M. (2002). Classification and regression by randomForest. *R news*, *2*(3), 18-22.

Lin, C. S., Khan, H. A., Chang, R. Y. ve 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, C.-F., Yeh, C.-Y. ve Lee, S.-J. (2012). Application of type-2 neuro-fuzzy modeling in stock price prediction. *Applied Soft Computing*, 12(4), 1348-1358. https://doi.org/10.1016/j.asoc.2011.11.028

Liu, L., Chen, C. ve 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. ve Singleton, K. J. (2011). How sovereign is sovereign credit risk?. *American Economic Journal: Macroeconomics*, *3*(2), 75-103.

Lundberg, S. ve Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions (No. arXiv:1705.07874). arXiv.

Meng, Y., Yang, N., Qian, Z. ve Zhang, G. (2020). What makes an online review more helpful: an interpretation framework using XGBoost and SHAP values. *Journal of Theoretical and Applied Electronic Commerce Research*, 16(3), 466-490.

Metz, C. E. (1978). Basic principles of ROC analysis. *Seminars in Nuclear Medicine*, 8(4), 283-298. https://doi.org/10.1016/S0001-2998(78)80014-2

Milesi-Ferretti, G. M. ve Razin, A. (1996). *Current-account sustainability*. International Finance Section, Princeton University.

Minsky Ph D, H. P. (1986). Stabilizing an Unstable Economy: The Lessons for Industry, Finance and Government. https://digitalcommons.bard.edu/hm_archive/513

Minsky, H. P. (1995). *Sources of Financial Fragility: Financial Factors in the Economics of Capitalism*. Levy Economics Institute of Bard College, Hyman P. Minsky Archive, Paper 69.

Mishkin, F. S. (1996). The channels of monetary transmission: Lessons for monetary policy.

Mitchell, R. ve Frank, E. (2017). Accelerating the XGBoost algorithm using GPU computing. *PeerJ Computer Science*, 3, e127.

Nazareth, N. ve Ramana Reddy, Y. V. (2023). Financial applications of machine learning: A literature review. *Expert Systems with Applications*, 219, 119640.

Nikou, M., Mansourfar, G. ve Bagherzadeh, J. (2019). Stock price prediction using deep learning algorithm and its comparison with machine learning algorithms. *Intelligent Systems in Accounting Finance & Management*, 26(4), 164-174. https://doi.org/10.1002/isaf.1459

O'Brien, M. ve Wosser, M. (2018). An Early Warning System for Systemic Banking Crises: A Robust Model Specification. *Central Bank of Ireland Research Technical Paper*, 9.

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. (2012). Does the current account still matter?. *American Economic Review*, 102(3), 1-23.

Obstfeld, M. ve Rogoff, K. (1996). *Foundations of international macroeconomics*. MIT press.

Òscar Jordà, Moritz Schularick, and Alan M. Taylor. (2017). *Macrofinancial History and the New Business Cycle Facts*. in NBER Macroeconomics Annual 2016, volume 31, edited by Martin Eichenbaum and Jonathan A. Parker. Chicago: University of Chicago Press.

Osman, A. I. A., Latif, S. D., Boo, K. B. W., Ahmed, A. N., Huang, Y. F. ve El-Shafie, A. (2024). Advanced machine learning algorithm to predict the implication of climate

change on groundwater level for protecting aquifer from depletion. *Groundwater for Sustainable Development*, 25, 101152. https://doi.org/10.1016/j.gsd.2024.101152

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. ve Manera, C. (2024). Bond yield spreads and exchange market pressure in emerging countries. *International Journal of Emerging Markets*.

Pentecost, E. J., Van Hooydonk, C. ve Van Poeck, A. (2001). Measuring and estimating exchange market pressure in the EU. *Journal of International Money and Finance*, *20*(3), 401-418.

Phillips, P. C. B. ve Shi, S. (2020). Real time monitoring of asset markets: Bubbles and crises. In *Handbook of statistics* (Vol. 42, pp. 61-80). Elsevier.

Phillips, P. C. B., Shi, S. ve Yu, J. (2015a). Testing for multiple bubbles: Historical episodes of exuberance and collapse in the S&P 500. *International Economic Review*, 56(4), 1043-1078. https://doi.org/10.1111/iere.12132

Polat, O. ve Ozkan, I. (2019). Transmission mechanisms of financial stress into economic activity in Turkey. *Journal of Policy Modeling*, *41*(2), 395-415.

Pontines, V. ve 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.

Qin, C., Zhang, Y., Bao, F., Zhang, C., Liu, P. ve Liu, P. (2021). XGBoost optimized by adaptive particle swarm optimization for credit scoring. *Mathematical Problems in Engineering*, 2021(1), 6655510.

Reinhart, C. M. ve Rogoff, K. S. (2011). From financial crash to debt crisis. *American economic review*, *101*(5), 1676-1706.

Reinhart, C. M. ve Rogoff, K. S. (2011). *This Time Is Different: Eight Centuries of Financial Folly*. Princeton University Press. https://doi.org/10.1515/9781400831722

Rodrik, D. (2008). The real exchange rate and economic growth. *Brookings papers on economic activity*, *2008*(2), 365-412.

Rouf, N., Malik, M., Arif, T., Sharma, S., Singh, S., Aich, S. ve Kim, H. (2021). Stock market prediction using machine learning techniques: A decade survey on methodologies, recent developments, and future directions. *Electronics*, 10(21), 2717. https://doi.org/10.3390/electronics10212717

Sağlam Bezgin, M. ve Başar, M. (2020). The research of asset price bubble at Borsa Istanbul and financial crisis relationship. *Anadolu University Journal of Social Sciences*, 20(2), 143-156.

Santero, T. ve Westerlund, N. (1996). *Confidence indicators and their relationship to changes in economic activity* (No. 170). OECD Publishing.

Santoni, G. J. (1987). The great bull markets 1924-29 and 1982-87: Speculative bubbles or economic fundamentals. *Federal Reserve Bank of St. Louis Review*, 69(9), 16-29.

Schularick, M., Taylor, A.M., (2012). *Credit booms gone bust: monetary policy, leverage cycles and financial crises*, 1870-2008. Am. Econ. Rev. 102 (2), 1029–1061. doi: 10.1257/aer.102.2.1029

Shankarpandala, S. (2024). *LazyPredict: A library for quick and easy model Selection İn Machine Learning*. https://pypi.org/project/lazypredict/

Shapley, L. S. (1953). *A Value For N-Person Games*. Contribution to the Theory of Games, 2.

Shi, S. P., Phillips, P. C. ve Yu, J. (2011). Specification sensitivities in right-tailed unit root testing for financial bubbles. *Hong Kong Institute for Monetary Research Working Paper*, 17.

Shiller, R. J. (2000). *Irrational Exuberance: (Second Edition)*. Princeton University Press.

Soe, T. T. ve Kakinaka, M. (2018). Inflation targeting and exchange market pressure in developing economies: Some international evidence. *Finance Research Letters*, 24, 263-272.

Söyler, H. ve Kızılkaya, O. (2018). Para krizlerinin yapay zeka yöntemleri ile tahmini: Türkiye örneği. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 649-666.

Stiglitz, J. E. (1990). Symposium on bubbles. *Journal of Economic Perspectives*, 4(2), 13-18.

Stolbov, M. ve 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.

Tran, K. L., Le, H. A., Lieu, C. P. ve Nguyen, D. T. (2023). Machine learning to forecast financial bubbles in stock markets: Evidence from Vietnam. *International Journal of Financial Studies*, 11(4), 133. https://doi.org/10.3390/ijfs11040133

Tran, K. L., Le, H. A., Nguyen, T. H. ve Nguyen, D. T. (2022). Explainable Machine Learning for Financial Distress Prediction: Evidence from Vietnam. *Data*, 7(11), 160.

Truong, C., Sheen, J., Trück, S. ve 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.

Uğuz, S. (2019). Makine öğrenmesi teorik yönleri ve Python uygulamaları ile bir yapay zekâ ekolü. Ankara: Nobel Yayıncılık.

Ünal, S. (2021). Makro Ekonomik Faktörler ile Borsa İstanbul Hisse Senedi Endekslerinin Getirileri Arasındaki İlişki. *Pamukkale University Journal of Social Sciences Institute/Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (47).

Ural, M. & Balaylar, N.A. (2007). Bankacılık sektöründe yüksek risk alımı ve baskı indeksleri. *Finans Politik & Ekonomik Yorumlar*, 44, 509.

Ural, M. (2022). Varlık fiyatlarında spekülatif fiyat baloncuklarının sağ kuyruklu ADF yöntemiyle analizi. *İzmir İktisat Dergisi*, 37(1), 189-205. https://doi.org/10.24988/ije.910996

Vašíček, B., Žigraiová, D., Hoeberichts, M., Vermeulen, R., Šmídková, K. ve de Haan, J. (2017). Leading indicators of financial stress: New evidence. *Journal of Financial Stability*, 28, 240-257.

Yildirim, I., Ozsahin, S. ve Akyuz, K. C. (2011). Prediction of the financial return of the paper sector with artificial neural networks. *BioResources*, *6*(4).

Zeren, F. ve Yılancı, V. (2019). Are there multiple bubbles in the stock markets? Further evidence from selected countries. *Ekonomika*, 98(1), 81-95. https://doi.org/10.15388/ekon.2019.1.5