

BİR MAKİNE ÖĞRENİMİ UYGULAMASI: G7 ÜLKELERİNDE FİNANSAL KRİZ TAHMİNLEME

A Machine Learning Approach: Financial Crisis Forecasting in G7 Countries

Merve MERT SARITAŞ*^{ID} & Mert URAL**^{ID}

Öz

Bu çalışma, sistemik bankacılık krizlerini tahmin etmede makine öğrenmesi yöntemlerinin etkinliğini, özellikle karmaşık ve doğrusal olmayan örüntüleri yakalama yeteneğiyle öne çıkan XGBoost algoritmasını kullanarak arařtırmaktadır. 1870-2020 dönemi için G7 ülkelerine ait finansal ve makroekonomik veriler kullanılarak sistemik bankacılık kriz tahmininde XGBoost tabanlı bir model geliştirilmiştir. Ayrıca, modelin 'kara kutu' doğasını aşarak karar alma süreçlerini derinlemesine anlamlandırmak amacıyla SHAP (SHapley Additive exPlanations) yöntemleri uygulanarak model sonuçları arasındaki nedensel ilişkiler analiz edilmiş, böylece tahmin edici değişkenler ile kriz riski arasındaki nedensel ilişkiler şeffaf bir şekilde analiz edilmiştir. 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 sağlam ve güvenilir bir analitik altyapı sunarak finansal kriz tahmininde makine öğrenmesi yöntemlerinin potansiyelini vurgulamaktadır.

Anahtar Kelimeler:

Finansal Krizler,
Makine Öğrenimi,
XGBoost,
SHAP Değeri,
Tahminleme

JEL Kodları:

C53, E44, G01, N10

Abstract

This study investigates the effectiveness of machine learning methods in predicting systemic banking crises, particularly using the XGBoost algorithm, which stands out for its ability to capture complex and non-linear patterns. A XGBoost-based model was developed to predict systemic banking crises using financial and macroeconomic data from G7 countries for the period 1870-2020. Additionally, SHAP (SHapley Additive exPlanations) methods were applied to analyze the causal relationships between model results, thereby overcoming the model's "black box" nature and providing a deeper understanding of decision-making processes. This allowed for a transparent analysis of the causal relationships between predictive variables and crisis risk. The findings demonstrate that XGBoost exhibits high predictive performance, offering new opportunities for practitioners and policymakers in assessing crisis risk. Additionally, SHAP values significantly enhance the transparency and accountability of machine learning models by revealing the complex relationships between predictive variables and crisis risk. This approach provides a robust and reliable analytical framework for identifying the fundamental economic drivers of financial crises, highlighting the potential of machine learning methods in financial crisis prediction.

Keywords:

Financial Crises,
Machine Learning,
XGBoost,
SHAP Value,
Forecasting.

JEL Codes:

C53, E44, G01, N10

* Arş. Gör., Çanakkale Onsekiz Mart Üniversitesi, Siyasal Bilgiler Fakültesi, İktisat Bölümü, Türkiye, merve.mertsaritas@comu.edu.tr

** Prof. Dr., Dokuz Eylül Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İktisat Bölümü, Türkiye, mert.ural@deu.edu.tr

Makale Geliş Tarihi (Received Date): 19.02.2025 Makale Kabul Tarihi (Accepted Date): 04.04.2025

Bu eser Creative Commons Atıf 4.0 Uluslararası Lisansı ile lisanslanmıştır.



1. Giriş

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 kırılma noktalarının 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. Küresel finansal sistemin işleyişi ve istikrarı açısından G7 ülkeleri (Almanya, Amerika Birleşik Devletleri, Birleşik Krallık, İtalya, Fransa, Japonya, Kanada) kritik bir öneme sahiptir. Dünya GSYİH’sinin yaklaşık %43’ünü oluşturan bu ileri ekonomiler, sahip oldukları büyük merkez bankaları, ihraç ettikleri başlıca rezerv para birimleri ve küresel sermaye akımlarını yönlendirme kapasiteleriyle uluslararası finansal mimarinin şekillenmesinde belirleyici bir rol oynamaktadırlar (World Bank, 2023). Sonuç olarak, G7 ekonomilerinde yaşanan makroekonomik dalgalanmalar, küresel sermaye hareketleri ve finansal istikrar üzerinde doğrudan ve sistemik etkiler yaratma potansiyeline sahiptir. Ayrıca, bu ülkeler bankacılık sektörü açısından 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 katkılarında biri tahmin modelinin güvenilirliğini ekonometri uzmanlarına ve politika yapıcılara gösterebilmek amacıyla makine öğrenimi 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 saęlamaktadır. Çeřitli ÷lkelerden elde edilen deneyimlerin bir araya getirilmesi finans ve bankacılık dñzenlemelerinde hem kñresel eęilimleri hem de yerel gerekleri dikkate alan kapsamlı bir yaklařıma duyulan ihtiyaı vurgulamaktadır.

řekil 1’de G7 ÷lkelerinde yařanan finansal kriz yoęunluęu haritası oluřturulmuřtur. Önerilen yöntem, řekil 2’de gösterildięi gibi altı ařamadan oluřan sistematik bir veri analizi ve modelleme sürecidir. Bu süreç řu adımları içermektedir: veri toplama, veri ön iřleme, sınıf dengesizlięi giderme, model oluřturma, performans deęerlendirme ve Açıklanabilir YZ (XAI) ile sonuların yorumlanması. Bu adımlar, veri analizi sürecinin güvenilir ve anlaşılır sonular üretmesini hedeflemektedir.



řekil 1. G7 ÷lkelerinde Yařanan Finansal Kriz Yoęunluęu.



řekil 2. Yöntem Akışı

Çalıřmanın ikinci bölümünde, kapsamlı bir literatür taraması sunulmuř, üçñcñ bölümünde metodolojiye yer verilerek uygulanan makine öğrenme modeli ve Shapley deęeri çerçevesi özetlenmiřtir. Dñrdñcñ bölümde veri seti ile tahmin edici deęiřkenlere iliřkin detaylı bilgi verilmiřtir. Bu bölümde ayrıca Shapley deęerleri aracılıęıyla tahmin edicileri göreli önem düzeyleri ortaya koyulmuřtur. Son olarak beřinci bölümde, çalıřmanın temel bulguları özetlenerek ekonomik yorumuna yer verilmiřtir.

Mevcut literatürde, G7 ÷lkelerinde sistemik bankacılık krizlerinin makine öğrenimi tabanlı tahminine odaklanan çalıřmaların yetersizlięi göze çarpmaktadır. Bu çalıřma,

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 ön işleme 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.

2. Literatür Taraması

Finansal krizlerin köklü bir geçmişe sahip olmasına karşın ülkeler arası panel veri setlerine dayalı erken uyarı modelleri 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-finance büyüklüklerin bu olayları öngörmeye 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-finance 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.

Geçmiřte 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 sergilediđi gösterilmiştir. Vařićek vd. (2017) finansal krizleri öngöreceğ göstermeleri belirlemek için 25 OECD ülkesinden elde edilen veriler üzerinde Bayesian Model Ortalaması uygulamış ve doğrusal modellerin finansal dinamikleri yakalayamadıđı ve finansal stresi tahmin edemediđini vurgulamıştır.

Makine öğrenmesi yöntemleriyle finansal krizleri tahmin etmek için Alessi ve Detken (2018), tarafından yürütölen bir arařtırmada, Avrupa Birliđi (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 deđişkenler olarak belirlenmiştir. Çalışmanın sonuçları, rastgele orman modelinin kayda deđer bir tahmin performansı sergilediđini ve makroekonomik verilerden yararlanarak erken uyarı sistemlerinin oluşturulması konusunda gelecek vaat ettiđini ortaya koymuştur. Bu bulgular, rastgele orman gibi makine öğrenimi tekniklerinin finansal istikrarın izlenmesi ve risk yönetimi alanlarında önemli katkılar sağlayabileceđini göstermektedir. Chatzis vd. (2018), Rastgele Orman, sınıflandırma ağaçları, Destek Vektör Makineleri (DVM), XGBoost ve İleri Beslemeli Sinir Ağları'nın (FFNN) performansını ampirik olarak karşılařtırmışlar ve en iyi sonucu XGBoost yönteminin verdiđi sonucuna ulaşmışlardır.

Tran vd. (2022) tarafından gerçekleştirilen yakın tarihli bir arařtırma, Vietnam borsasında 2010-2021 yılları arasında işlem gören řirketlere ait bir veri seti üzerinde karmařık makine öğrenimi modellerinin tahmin sonuçlarını yorumlamak için Shapley deđerlerinden yararlanmıştır. Bu çalışmanın bulguları, aşırı gradyan güçlendirme (Extreme Gradient Boosting) ve rastgele orman (Random Forest) modellerinin diđer makine öğrenimi modellerine kıyasla daha yüksek performans gösterdiđini ortaya koymuştur. Çalışmanın dikkat çekici bir yönü ise yazarların Shapley deđerlerini kullanarak her bir özelliđin tahmin sonuçları üzerindeki etkisini detaylı bir şekilde analiz etmesi ve bu sayede teorik çerçevede öngörölmeyen ilişkiler hakkında ek bilgiler sunmalarıdır. Bu yaklařım, makine öğrenimi modellerinin karar verme süreçlerini daha řeffaf hale getirerek ilgili alanlardaki arařtırmacılar ve uygulayıcılar için deđerli içgörüler sağlamaktadır. Liu vd. (2022), daha etkili tahmin göstergelerini belirlemek ve makine öğrenimi modellerinin nedensel ilişkilerini analiz etmek amacıyla Shapley deđerli ayrıştırma ve Shapley regresyon yöntemlerini kullanmışlardır. Chen vd. (2024) logit modeli ve diđer derin öğrenme modellerini karşılařtırarak erken uyarı sisteminin yorumlanabilirliđi için Shapley deđer ayrışımı hesaplamıştır. Çalışmanın ampirik sonuçları TCN'nin diđer modellerden daha iyi performans gösterdiđini ve hisse senedi fiyatı ve reel GSYİH büyümesinin kriz tahmininde en büyük katkıya sahip olduđunu göstermektedir.

Bu çalışma, finansal krizler bağlamında gelişmiş ekonometrik ve makine öğrenimi teknikleri aracılıđıyla G7 ölkelerinde sistemik bankacılık krizlerini tahmin ederek literatöre önemli bir katkı sağlamaktadır. Öncelikle, dengesiz veri kümeleri için uygun olan yöntemler kullanılarak veri ön işleme aşaması detaylı bir şekilde tamamlanmıştır. İkinci olarak söz konusu problemi ele almak için ilgili bir makine öğrenimi tekniđi olan XGBoost yöntemi kapsamlı bir şekilde incelenmiştir. Daha sonra bu modelleme tekniđinin etkinliđini deđerlendirmek amacıyla model doğrulama süreçleri uygulanmış ve performans ölçütleri kullanarak modelin başarıımı deđerlendirilmiştir. Son olarak SHAP analizleriyle finansal kriz tahmin görevini yerine getirmek

için kullanılabilir ve büyük finansal piyasaların tüm yelpazesini kapsayan genişletilmiş bir açıklayıcı değişkenler kümesinin kapsamlı bir incelemesi sunulmuştur.

3. Metodoloji

3.1. 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 düzenleme (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 Denklem (1)'deki gibidir. Burada $L^{(t)}$ ile ifade edilen bir kayıp fonksiyonudur. $\Omega(\phi_t)$ ise modelin karmaşıklığını tanımlayan bir düzenleme 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 düzenleme teriminden oluşur. Kayıp fonksiyonu tahmin edilen ve gerçek değerler arasındaki farkı ölçerken, düzenleme terimi aşırı öğrenmeyi engellemektedir.

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

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. SHAP Analizi

Bu alıřma, iřbirliki oyun teorisinin temel kavramlarından olan Shapley deęerlerini (Shapley, 1953) kullanarak makine ęrenimi modellerindeki ngrclerin katkılarını deęerlendirmeyi amalamaktadır. Shapley deęerleri, her bir ngrcnn model ıktısına yaptığı katkıyı nicelendirmek iin kullanılmaktadır. Lundberg ve Lee (2017) tarafından geliřtirilen SHAP (SHapley Additive exPlanations) kavramı ise her bir zellięin tahminlere olan katkısını hesaplayarak makine ęrenimi modellerinin yaptığı tahminleri daha anlařılır kılmayı hedeflemektedir. Bu sayede karmařık modellerin karar alma sreleri řeffařlařır.

4. Uygulama

4.1. Veriler

G7 lkeleri iin kullanılan veriler Jrda-Schularick-Taylor makro tarih veri tabanından alınmıřtır (Jord vd., 2017). Veri seti, sistemik finansal krizleri “bir lkenin bankacılık sektrnn, kamu mdahalesi, iflas veya finansal kurumların zorunlu birleřmesi ile sonulanan byk sermaye kayıplarının eřlik ettięi temerrt oranlarında keskin artıřlar yařadığı olaylar” olarak sınıflandırmaktadır (Schularick ve Taylor, 2012). alıřmada finansal piyasadaki kriz durumu 0 ve 1 deęerlerine sahip ikili (binary) bir deęiřken olarak tanımlanmıřtır. Bu yaklařım, ikili hedefli makine ęrenimi yntemlerinin kullanılmasını mmkn kılmakta ve hedef deęiřkenin daha kolay tahmin edilmesini saęlamaktadır. alıřmada kriz durumunun baęımlı deęiřken olarak ele alınması yalnızca ařırı uyum olasılıęını azaltmakla kalmayıp aynı zamanda piyasadaki kriz durumunun daha net bir řekilde temsil edilmesine olanak tanımaktadır. Sonu olarak bu yaklařım makine ęrenimi modellerinin tahmin doęruluęunu artırmaya katkı saęlamaktadır.

Sistemik kriz, bir bankanın yařadığı sorunların dięer bankaları da etkileyerek tm finansal sistemi tehdit ettięi bir durumdur. Dřk sermaye yeterlilięi, yksek faiz oranları ve yksek enflasyon gibi faktrler sistemik riski artırabilir. Sistematik bankacılık krizlerini tahmin etmek iin kullanılan gstergeler arasında kredi ile ilgili gstergeler, makroekonomik gstergeler; GSYH ve piyasa ile ilgili gstergeler (faiz oranları) bulunmaktadır (Nazareth ve Ramana Reddy, 2023). Makroekonomik ortamı ve ekonomik faaliyetleri yansıtmak amacıyla GSYH byme oranı ve enflasyon oranı olmak zere iki standart konjonktr gstergesi kullanılmıřtır. ılımlı GSYH bymesi ekonomik istikrarı yansıtırken hızlı veya dřk GSYH bymesi kırılganlığın endiře verici bir iřareti olabilir (Kauko, 2014). Ařırı ısınmıř ekonomiler, sermaye akıřları yoluyla sınır tesine aktarılabilen dıřsal risklere karřı daha savunmasızdır (Jord vd., 2011). Dięer yandan, yavař veya olumsuz ekonomik geliřmeler reel ekonomik zayıflıklara iřaret ederek potansiyel olarak krizlere yol aabilir. Benzer řekilde yksek enflasyon makro-finance istikrarsızlıklara iřaret edebilirken, ok dřk enflasyon veya deflasyon da tketicilerin harcamalarını kısıtladığı ve hatta resesyona neden olabileceęi iin endiře verici bir durumdur.

Gemiřte yařanan ok sayıda kriz ve 2007/2008 kresel finans krizi ncesinde birok sanayi lkesinde byk cari aıkların grlmesi, cari iřlemler dengesizliğinin makro-finance kırılganlığın potansiyel bir kaynağı olduęunu ve bu nedenle dzenleyicilerin ilgi odağı olması gerektięini ortaya koymaktadır (Obstfeld, 2012). Bu nedenle, sistemik kriz tahminlemesi gstergelerinde cari hesap/GSYH oranı bir gsterge 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 1. Kriz Tahminlemesinde Kullanılan Değişkenler ve Açıklamaları

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)

Bu çalışmada finansal krizlerin makine öğrenmesi yöntemleriyle tahminlenmesi kapsamında aşağıda Tablo 1'de yer alan değişkenler kullanılmıştır. Tablo, makroekonomi ve finans literatüründe kriz tahminindeki etkinlikleri ve sundukları anlamlı sonuçlar ile kabul görmüş 11 makroekonomik ve finansal değişkenden oluşmaktadır. Model parametrelerini optimize etmek ve genelleme yeteneğini değerlendirmek amacıyla sırasıyla eğitim veri seti (X) ve test veri seti (y) kullanılmış, veri setinin %80'i eğitim ve %20'si test için ayrılmıştır.

4.2. 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 2'de sunulan tahmin sonuçlarıyla detaylandırılmıştır.

Tablo 2. G7 Ülkeleri için LazyPredict XGBoostClassifier Tahmin Sonuçları

	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	1.0000	1.0000	0.0586
İtalya	1.0000	1.0000	0.0588
Japonya	0.9677	0.9519	0.0722
Kanada	1.0000	1.0000	0.0527

4.3. 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 (XGBoost) 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.

Model karmaşıklığı, özellik örnekleme 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 3'te G7 ülkelerinden elde edilen sonuçlar ışığında, finansal krizleri en yüksek model performansı ile tahminleyen optimal parametre değerleri belirtilmiştir. Bu parametreler, her ülkenin kendi veri yapısına ve dinamiklerine göre modelin en iyi genelleme yeteneğine sahip olmasını sağlamak üzere optimize edilmiştir. Farklı ülkeler için farklı optimal parametrelerin bulunması, XGBoost gibi algoritmaların esnekliğini ve veri odaklılığını göstermektedir.

Tablo 3. Model İyileştirme (Tuning) Sonrası En İyi Parametreler

Parametreler / Ülke	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

G7 ülkeleri için XGBoost model tuning sonuçlarına göre, ABD, Almanya, İngiltere, Fransa ve Kanada için genellikle sığ ağaçlar (max_depth=3) tercih edilmiştir. ABD ve Fransa orta düzeyde öğrenme oranı (0.20) ile çalışırken, Almanya daha agresif (0.30), İngiltere ve Kanada ise muhafazakâr (0.05) oranlar kullanmıştır. Ağaç sayısı ülkeler arasında değişmekle birlikte, Japonya (3000) ve Fransa-İtalya (750) yüksek değerlerle öne çıkmaktadır. İtalya farklı olarak derin ağaçlar (max_depth=7), Japonya ise orta derinlikte ağaçlar (max_depth=5) kullanmıştır. Gamma regülerizasyonu Fransa (0.2), Japonya (0.2) ve ABD (0.1) için uygulanırken, diğer ülkelerde kullanılmamıştır. Özellik ve örneklem oranları genelde %70–%100 aralığında kalmış, modeller ülkelere göre farklı öğrenme stratejileri yansıtmıştır. Bu sonuçlar, her ülkenin veri setindeki ilişkilerin ve yapısının farklı olduğunu ve en iyi model performansına ulaşmak için farklı hiperparametre ayarlamaları gerektiğini göstermektedir. Örneğin, İtalya için daha derin ağaçların gerekmesi, Japonya için ise çok sayıda ağaçla daha detaylı bir öğrenmenin optimum olması gibi farklılıklar dikkat çekicidir. Öğrenme oranları ve regülerizasyon parametrelerindeki çeşitlilik de her modelin aşırı öğrenmeden kaçınmak için farklı stratejiler benimsediğini ortaya koymaktadır.

5. Ampirik Bulgular

5.1. XGBoost Performans Sonuçları


Tablo 4'te 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. Bu metrikler, modelin genel sınıflandırma başarısını, pozitif ve negatif vakaları doğru tespit etme yeteneğini ve tahminlerinin istatistiksel güvenilirliğini ortaya koymaktadır.

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. Model, Japonya ve İtalya için ise çok yüksek ve dengeli bir performans sergilemiştir. Fransa'da doğruluk yüksek olmakla birlikte duyarlılık orta düzeydedir. Buna karşılık İngiltere için özellikle duyarlılık oranlarındaki düşüklükler, modelin performansının ülkelere göre değiştiğini ve bazı ülkelerde ek optimizasyonların gerekebileceğini işaret etmektedir. Bununla birlikte ABD modelinde doğruluk diğerlerine göre daha düşük ve tahmin belirsizliği daha yüksektir. Tüm ülkelerde özgüllük değerlerinin genel olarak yüksek olması (≥ 0.941), modelin negatif örnekleri tanımlamada tutarlı bir şekilde başarılı olduğunu göstermektedir. Duyarlılık metrikleri ise ülkeler arasında daha belirgin farklılıklar sergilemektedir. Bu tür farklılıklar güvenilir ve doğru tahminler elde etmek amacıyla uygulamalı makroekonomi çalışmalarında bağlama özgü model ayarlaması ve doğrulamanın kritik önemini vurgulamaktadır. Bu araştırma, G7 ülkeleri için geliştirilen modellerin performansını kapsamlı bir şekilde analiz etmekte ve her bir ülkeye özgü etkinlik düzeylerindeki farklılıkları (güçlü ve zayıf yönleri) ortaya koymaktadır. Bu ampirik bulgular temel alınarak, modellerin gelecekteki tahmin doğruluğunu ve güvenilirliğini artırmaya yönelik potansiyel iyileştirme stratejileri önerilmektedir.

Tablo 4. 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

Bununla birlikte Şekil 3'te 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 ayırım 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 3. G7 Ülkeleri için XGBoost ROC Eğrisi ve AUC Değeri


5.2. Değişkenlerin Önem Düzeyleri

Şekil 4'te 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 5'te 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.

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 artırılabilir. 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.

İtalya, ABD ve İngiltere için cari açığın GSYİH'ya oranının kriz tahmininde yüksek bir önem skoruna sahip olması, bu ülkelerde tarihsel olarak büyük ve/veya süregelen cari açıkların (veya bu açıkların finansman biçimindeki değişimlerin) finansal kriz riskini artıran önemli bir faktör olduğunu düşündürmektedir. Cari açığın yönetimi, genellikle uzun vadeli ve kapsamlı makroekonomik politika ayarlamaları gerektirir. Tek bir "kontrol" mekanizması olmamakla

birlikte, kullanılabilecek temel politika araçları maliye politikası aracılığıyla ulusal tasarrufları artırmak/iç talebi kısmak ve para politikasıyla iç talep ile kur dinamiklerini etkilemektir. Uzun vadeli çözüm için ise rekabet gücünü ve verimliliği artıracak yapısal reformlar ile ulusal tasarrufları teşvik edecek politikalar uygulamak esastır.



Şekil 4. G7 Ülkeleri İçin Potansiyel Kriz Tahmincileri

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.

Tablo 5. 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

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 yapıcılarının makro ihtiyati politikaları tasarlarırken 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 yapıcılarının ülkeye özgü kırılganlıkları ve risk faktörlerini dikkate alarak proaktif ve uyarlanabilir bir yaklaşım benimsemeleri finansal istikrarın sağlanması açısından elzemdir.

5.3. SHAP Değerleri


Şekil 5'te G7 ülkeleri için oluşturulan SHAP 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.

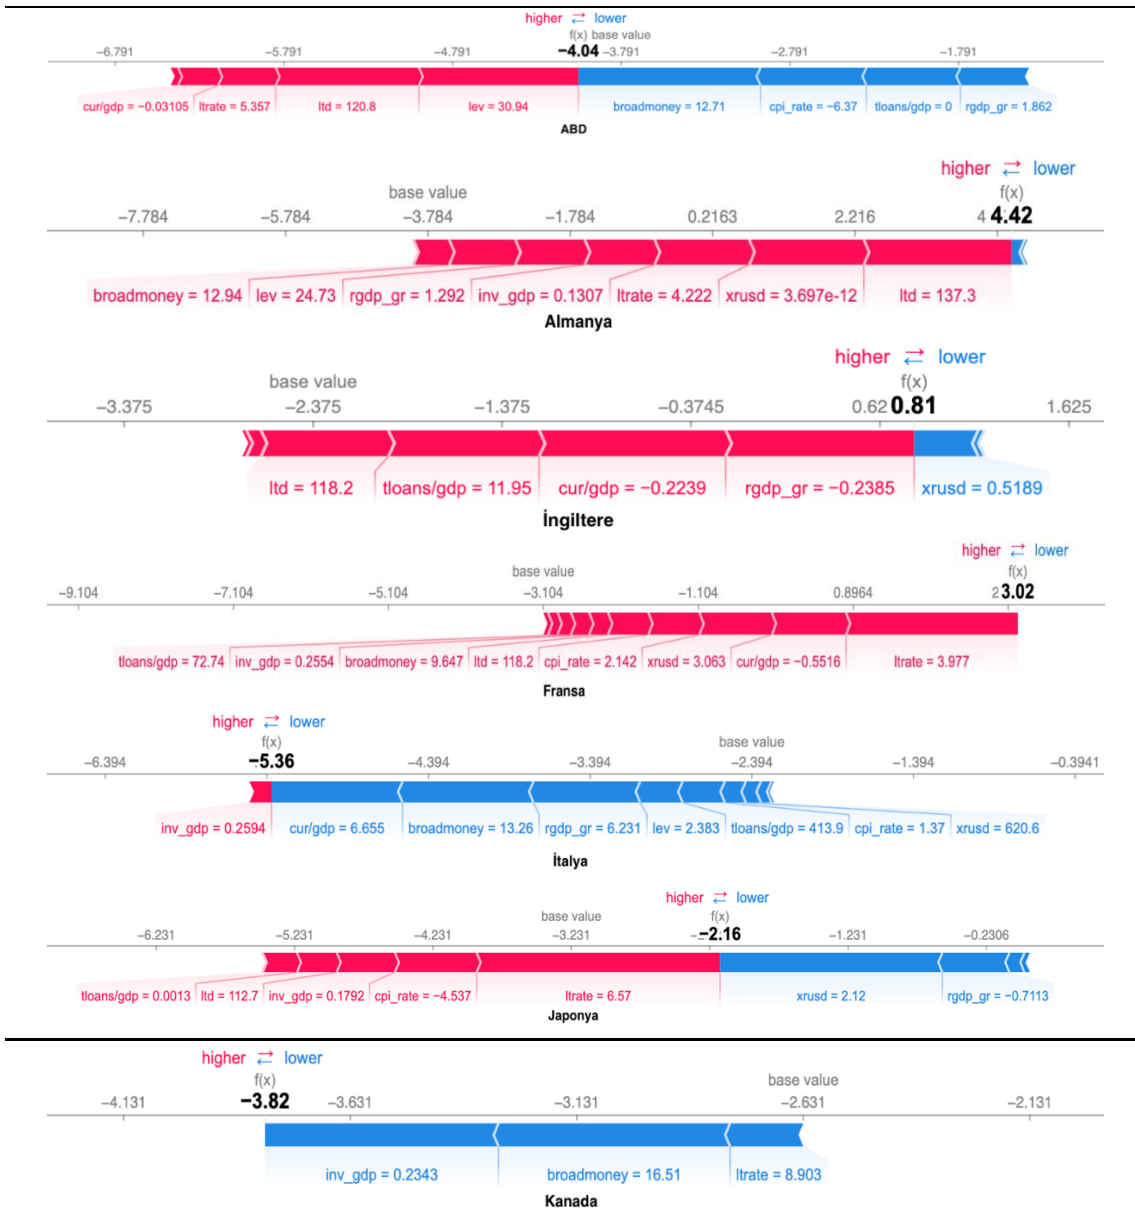
Para politikalarının önerilen şekilde dikkatlice yönetilmesi veya güçlendirilmesi, her ülkenin özel hedeflerine uygun araçların kullanılmasını içerir. Fransa’da enflasyon kontrolü için Avrupa Merkez Bankası’nın enflasyon beklentilerini çıpalamak ve politika adımlarının etkinliğini artırmak için %2’lik enflasyon hedefine bağlılığını ve gelecekteki politika niyetlerini net ve tutarlı bir şekilde piyasalara iletmesi ve bilanço politikalarını veri odaklı yönetmesi gerekirken, İtalya için likidite desteğinin enflasyon hedefiyle dengelenmesi ve muhtemelen hedefe yönelik araçların kullanılması önemlidir. Japonya’da kur istikrarını desteklemek amacıyla BoJ’un politika çerçevesini netleştirmesi ve uluslararası koordinasyonu gözetmesi, Kanada’da ise BoC’nin likidite sağlarken finansal riskleri sınırlamak için hedefli mekanizmalar uygulaması ve düzenleyici kurumlarla koordinasyonu kritik rol oynamaktadır. Bu yaklaşımlar, merkez bankalarının standart araçlarını spesifik ulusal ihtiyaçlara ve risklere göre uyarlamasını gerektirir.



Şekil 5. SHAP Analizi Sonuçları

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 6’da 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 6. SHAP Kuvvet Grafiği Sonuçları

Grafikte baz deęer (base value) modelin sistemik finansal kriz olasılıęı tahmininin bařlangıç noktasıdır. Nihai tahmin $f(x)$ ise özelliklerin pozitif ve negatif katkıları toplanarak baz deęerinden hareketle hesaplanır. Kırmızı deęere sahip olan deęişkenler tahmini artırarak (kriz olasılıęını artırma yönünde) etki ederken mavi deęere sahip olan deęişkenler tahmini azaltarak (kriz olasılıęını düşürme yönünde) etki etmektedir.

ABD ekonomisi için XGBoost modeli ile yapılan sistemik finansal kriz tahminleme analizinde, bazı makroekonomik ve finansal deęişkenlerin kriz olasılıęı üzerindeki etkileri belirginleşmektedir. Cari işlemler açığının GSYİH'ye oranının düşüklüğü, uzun dönem faiz oranlarındaki artış, kredilerin mevduata oranının yükseklięi ve bankacılık kesimindeki sermaye oranının yükseklięi kriz olasılıęını artıran faktörler olarak öne çıkmaktadır. Bu durum, cari dengesizliklerin, yüksek borçlanma maliyetlerinin, aşırı kredi genişlemesinin ve bankaların sermaye yapılarındaki deęişimlerin finansal kırılganlıęı tetikleyebileceğine işaret etmektedir. Öte yandan düşük enflasyon ve reel GSYİH büyümesi kriz olasılıęını 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 olasılıęı üzerinde baskın bir etkiye sahip olduęu 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 yapımcıların özellikle bankacılık sektörünü yakından izlemesi ve kredi piyasasının sürdürülebilirlięini sağlamak için makro ihtiyati tedbirler alması gerektiğini vurgulamaktadır. İngiltere'de USD döviz kurunun kriz olasılıęını 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 yükseklięi ve bankacılık sektöründeki bazı göstergelerin kriz olasılıęı üzerinde önemli bir etkiye sahip olduęu 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 yükseklięi ve devamındaki deęişkenler kriz olasılıęını azaltan en önemli faktörler olarak öne çıkmaktadır. Japonya ekonomisinde ise bankacılık sektöründeki likidite risklerinin kriz olasılıęı üzerindeki etkileri öne çıkmaktadır. Döviz kurunun ve büyüme oranının kriz olasılıęını 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 deęişkenlerin kriz olasılıęını azaltıcı yönde etki ettiğini göstermektedir. Yatırımın GSYİH'ye oranı (inv_gdp), geniş para arzındaki büyüme (broadmoney) ve uzun dönem vadeli faiz oranları (rate) kriz olasılıęını 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 yapıcılarının 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.

6. 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 yapıcılarının 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 politikalarla 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 yapıcılarının 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 arařtırmalar, sistemik bankacılık krizlerinin lkeler arasındaki finansal ve ekonomik aktrler zerindeki yayılma etkilerini hem finansal hem de ticari baėlantıları dikkate alarak detaylı bir řekilde inceleyebilir. Sistemik bankacılık krizlerinin temel nedenlerinin ve uluslararası politika btnlėnn sz konusu krizlerin kresel istikrar zerindeki etkilerini azaltmadaki rolnn arařtırılması da alana nemli katkılar saėlayacaktır. Sonu olarak, makro ihtiyati politikaların tasarımı ve uygulanması, lke zelindeki risk faktrlerinin ve kresel ekonomik dinamiklerin dikkate alındıėı btncl bir yaklařımla gerekleřtirilmelidir. Makine ėrenimi modellerinin sunduėu ngr yeteneėi, politika yapıcılarının erken uyarı sistemlerini geliřtirmelerine ve proaktif nlemler almalarına yardımcı olabilir.

Arařtırma ve Yayın Etiėi Beyanı

Etik kurul izni ve/veya yasal/zel izin alınmasına gerek olmayan bu alıřmada arařtırma ve yayın etiėine uyulmuřtur.

Arařtırmacıların Katkı Oranı Beyanı

Yazarlar makaleye eřit oranda katkı saėlamıř olduklarını beyan eder.

Arařtırmacıların ıkar atıřması Beyanı

Bu alıřmada herhangi bir potansiyel ıkar atıřması bulunmamaktadır.

Kaynakça

- Aikman, D., Galesic, M., Gigerenzer, G., Kapadia, S., Katsikopoulos, K., Kothiyal, A., Murphy, E. and Neumann, T. (2021). Taking uncertainty seriously: Simplicity versus complexity in financial regulation. *Industrial and Corporate Change*, 30(2), 317-345. <https://doi.org/10.1093/icc/dtaa024>
- Akinci, O. and Olmstead-Rumsey, J. (2018). How effective are macroprudential policies? An empirical investigation. *Journal of Financial Intermediation*, 33, 33-57. <https://doi.org/10.1016/j.jfi.2017.04.001>
- Aksoy, N. and Genc, I. (2023). Predictive models development using gradient boosting based methods for solar power plants. *Journal of Computational Science*, 67, 101958. <https://doi.org/10.1016/j.jocs.2023.101958>
- Alessi, L. and Detken, C. (2018). Identifying excessive credit growth and leverage. *Journal of Financial Stability*, 35, 215-225. <https://doi.org/10.1016/j.jfs.2017.06.005>
- Babecký, J., Havránek, T., Matějů, J., Rusnák, M., Šmídková, K. and Vašíček, B. (2014). Banking, debt, and currency crises in developed countries: Stylized facts and early warning indicators. *Journal of Financial Stability*, 15, 1-17. <https://doi.org/10.1016/j.jfs.2014.07.001>
- Berg, A. and Pattillo, C. (1999). Are currency crises predictable? A test. *IMF Staff Papers*, 46(2), 107-138. <https://doi.org/10.2307/3867664>
- Bluwstein, K., Buckmann, M., Joseph, A., Kapadia, S. and Şimşek, Ö. (2023). Credit growth, the yield curve and financial crisis prediction: Evidence from a machine learning approach. *Journal of International Economics*, 145, 103773. <https://doi.org/10.1016/j.jinteco.2023.103773>
- Brunnermeier, M.K. and Oehmke, M. (2013). Bubbles, Financial crises, and systemic risk. In G.M. Constantinides, M. Harris and R.M. Stulz (Eds.), *Handbook of the economics of finance* (pp. 1221-1288). <https://doi.org/10.1016/B978-0-44-459406-8.00018-4>
- Cardarelli, R., Elekdag, S. and 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>
- Chatzis, S.P., Siakoulis, V., Petropoulos, A., Stavroulakis, E. and Vlachogiannakis, N. (2018). Forecasting stock market crisis events using deep and statistical machine learning techniques. *Expert Systems with Applications*, 112, 353-371. <https://doi.org/10.1016/j.eswa.2018.06.032>
- Chawla, N.V., Bowyer, K.W., Hall, L.O. and Kegelmeyer, W.P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321-357. <https://doi.org/10.1613/jair.953>
- Chen, S., Huang, Y. and Ge, L. (2024). An early warning system for financial crises: A temporal convolutional network approach. *Technological and Economic Development of Economy*, 30(3), 688–711. <https://doi.org/10.3846/tede.2024.20555>
- Dabrowski, J.J., Beyers, C. and de Villiers, J.P. (2016). Systemic banking crisis early warning systems using dynamic Bayesian networks. *Expert Systems with Applications*, 62, 225-242. <https://doi.org/10.1016/j.eswa.2016.06.024>
- Dhaliwal, S.S., Nahid, A.-A. and Abbas, R. (2018). Effective intrusion detection system using XGBoost. *Information*, 9(7), 149. <https://doi.org/10.3390/info9070149>
- Giese, J., Nelson, B., Tanaka, M. and Tarashev, N.A. (2013). *How could macroprudential policy affect financial system resilience and credit? Lessons from the literature* (Bank of England Financial Stability Paper No. 21). <https://doi.org/10.2139/ssrn.2266366>
- He, Y., Lu, X., Fournier-Viger, P. and Huang, J.Z. (2024). A novel overlapping minimization SMOTE algorithm for imbalanced classification. *Frontiers of Information Technology & Electronic Engineering*, 25(9), 1266-1281. <https://doi.org/10.1631/FITEE.2300278>
- Hoggarth, G., Reis, R. and Saporta, V. (2002). Costs of banking system instability: Some empirical evidence. *Journal of Banking & Finance*, 26(5), 825-855. [https://doi.org/10.1016/S0378-4266\(01\)00268-0](https://doi.org/10.1016/S0378-4266(01)00268-0)

- Jordà, Ò., Schularick, M. and Taylor, A.M. (2011). Financial crises, credit booms, and external imbalances: 140 years of lessons. *IMF Economic Review*, 59(2), 340-378. <https://doi.org/10.1057/imfer.2011.8>
- Kaminsky, G.L. and Reinhart, C.M. (1999). The twin crises: The causes of banking and balance-of-payments problems. *American Economic Review*, 89(3), 473-500. doi:10.1257/aer.89.3.473
- Kauko, K. (2014). How to foresee banking crises? A survey of the empirical literature. *Economic Systems*, 38(3), 289-308. <https://doi.org/10.1016/j.ecosys.2014.01.001>
- Kindleberger, C.P. (2000). Manias, panics, and crashes: A history of financial crises. *The Scriblerian and the Kit-Cats*, 32(2), 379. Retrieved from <https://www.proquest.com/>
- Laeven, M.L. and Valencia, M.F. (2012). *Systemic banking crises database: An update* (IMF Working Paper No. 12/163). Retrieved from <https://www.imf.org/external/pubs/ft/wp/2012/wp12163.pdf>
- Laeven, M.L. and Valencia, M.F. (2018). *Systemic banking crises revisited* (IMF Working Paper No. 2018/206). Retrieved from <https://www.imf.org/en/Publications/WP/Issues/2018/09/14/Systemic-Banking-Crises-Revisited-46232>
- Levine, R. (2005). Finance and growth: Theory and evidence. In P. Aghion and S.N. Durlauf (Eds.), *Handbook of economic growth* (pp. 865-934). [https://doi.org/10.1016/S1574-0684\(05\)01012-9](https://doi.org/10.1016/S1574-0684(05)01012-9)
- Liu, L., Chen, C. and Wang, B. (2022). Predicting financial crises with machine learning methods, *Journal of Forecasting*, 41(5), 871-910. <https://doi.org/10.1002/for.2840>
- Lundberg, S. and Lee, S.-I. (2017). A unified approach to interpreting model predictions. In I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan and R. Garnett (Eds.), *Advances in neural information processing systems*. Papers presented at the NIPS2017, California: Curran Associates.
- Meng, Y., Yang, N., Qian, Z. and 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. <https://doi.org/10.3390/jtaer16030029>
- Minsky, H.P. (1995). *Sources of financial fragility: Financial factors in the economics of capitalism* (Levy Economics Institute of Bard College No. 69). Retrieved from https://digitalcommons.bard.edu/cgi/viewcontent.cgi?article=1068&context=hm_archive
- Mitchell, R. and Frank, E. (2017). Accelerating the XGBoost algorithm using GPU computing. *PeerJ Computer Science*, 3, e127. <https://doi.org/10.7717/peerj-cs.127>
- Nazareth, N. and Ramana Reddy, Y.V. (2023). Financial applications of machine learning: A literature review. *Expert Systems with Applications*, 219, 119640. <https://doi.org/10.1016/j.eswa.2023.119640>
- Obstfeld, M. (2012). Does the current account still matter? *American Economic Review*, 102(3), 1-23. doi: 10.1257/aer.102.3.1
- Jordà, Ò., Schularick, M. and Taylor, A.M. (2017). Macrofinancial history and the new business cycle facts. *NBER Macroeconomics Annual*, 31(1), 213-263. <https://doi.org/10.1086/690241>
- Osman, A.I.A., Latif, S.D., Boo, K.B.W., Ahmed, A.N., Huang, Y.F. and 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>
- Qin, C., Zhang, Y., Bao, F., Zhang, C., Liu, P. and Liu, P. (2021). XGBoost optimized by adaptive particle swarm optimization for credit scoring. *Mathematical Problems in Engineering*, 2021(1), 6655510. <https://doi.org/10.1155/2021/6655510>
- Reinhart, C.M. and Rogoff, K.S. (2011). *This time is different: Eight centuries of financial folly*. New Jersey: Princeton University Press. <https://doi.org/10.1515/9781400831722>
- Schularick, M. and Taylor, A.M. (2012). Credit booms gone bust: monetary policy, leverage cycles, and financial crises, 1870–2008. *American Economic Review*, 102(2), 1029-1061. doi:10.1257/aer.102.2.1029

- Shankarpandala, S. (2024). *LazyPredict: A library for quick and easy model selection in machine learning*. Retrieved from <https://pypi.org/project/lazypredict/>
- Shapley, L.S. (1953). A value for n-person games. In H.W. Kuhn (Ed.), *Classics in game theory* (pp. 307-317). New Jersey: Princeton University Press.
- Tölö, E. (2020). Predicting systemic financial crises with recurrent neural networks. *Journal of Financial Stability*, 49, 100746. <https://doi.org/10.1016/j.jfs.2020.100746>
- Tran, K.L., Le, H.A., Nguyen, T.H. and Nguyen, D.T. (2022). Explainable machine learning for financial distress prediction: Evidence from Vietnam. *Data*, 7(11), 160. <https://doi.org/10.3390/data7110160>
- Vařiček, B., Žigraiová, D., Hoerberichts, M., Vermeulen, R., Šmídková, K. and de Haan, J. (2017). Leading indicators of financial stress: New evidence. *Journal of Financial Stability*, 28, 240-257. <https://doi.org/10.1016/j.jfs.2016.05.005>
- World Bank. (2023). *World development indicators*. Retrieved from <https://databank.worldbank.org/source/world-development-indicators>

A MACHINE LEARNING APPROACH: FINANCIAL CRISIS FORECASTING IN G7 COUNTRIES

EXTENDED SUMMARY

The Purpose of the Study

The objective of this study is to empirically evaluate the efficacy of an XGBoost-based modelling approach in predicting systemic banking crises. This investigation utilizes financial and macroeconomic data from G7 countries from the period 1870 to 2020. The study aims to elucidate the causal relationships between crisis risk and forecasting variables through SHAP (SHapley Additive exPlanations) analyses. The findings of this study will provide policy recommendations to enhance financial stability.

Literature Review

The extant literature contains a paucity of studies that focus on the machine learning-based forecasting of systemic banking crises in G7 countries. The present study aims to address this gap in the literature by integrating advanced econometric analyses and machine learning techniques (in particular, the XGBoost algorithm) to evaluate time series data more effectively. The study's distinguishing features include the employment of suitable data preprocessing methodologies for imbalanced datasets, the rigorous evaluation of the efficacy of the XGBoost model through model validation processes, and a comprehensive examination of the factors involved in the prediction of financial crises through SHAP analyses. This provides a more robust and interpretable modelling framework for the early warning of financial crises.

Existing literature demonstrates the potential of machine learning methods for financial crisis prediction, offering advancements in financial stability monitoring and risk management. For example, Alessi and Detken (2018) found the random forest algorithm yielded promising results. Chatzis et al. (2018) reported that XGBoost outperformed alternative methods. More recently, researchers have focused on model interpretability. Tran et al. (2022) used Shapley values to interpret the predictive outputs of XGBoost and random forest models, increasing the transparency of the models' decision-making processes. Similarly, Liu et al. (2022) and Chen et al. (2024) employed Shapley values to identify impactful prediction indicators and analyze causal relationships within their models.

Methodology

This study utilizes XGBoost and SHAP values. XGBoost (Extreme Gradient Boosting), developed by Chen and Guestrin (2016), is an approach based on the boosting algorithm proposed by Friedman (2001). XGBoost is an ensemble model created by efficiently combining decision trees and thus offers higher prediction performance compared to stand-alone methods. These features have contributed to the widespread adoption of XGBoost as a preferred algorithm in machine learning applications. Additionally, XGBoost employs Shapley values

(Shapley, 1953), a fundamental concept in cooperative game theory, to evaluate the contributions of predictors in machine learning models.

Findings

The performance of extreme gradient boosting models varies significantly between countries, as indicated by the substantial differences in the diagnostic criteria. Specifically, the Canadian and German models demonstrate consistent superiority across all evaluation metrics, signifying their notable predictive capability. Conversely, the UK model exhibits comparatively low sensitivity ratios, suggesting that its performance is contingent on the specific context of each country and that additional optimizations may be necessary in certain instances. These observations underscore the paramount importance of adapting models to the unique characteristics of each country in applied macroeconomic studies, ensuring the reliability and precision of forecasts. In conclusion, this analysis reveals that G7 countries have different economic dynamics, and each country needs to develop its own policies to prevent crises. Therefore, it is essential for policymakers to adopt a proactive and adaptive approach by taking into account country-specific vulnerabilities and risk factors to ensure financial stability.

Conclusion and Policy Implications

In this study, economic policy recommendations are derived from SHAP summary graphs of systemic financial crisis forecasting analyses with the XGBoost classifier for G7 countries. This provides a strategic framework that takes into account the unique risk profiles and common trends of the countries. The findings of the study suggest that G7 countries should develop effective monetary and fiscal policy tools to minimize the effects of crisis periods. In this context, the Federal Reserve and other regulatory agencies should be able to respond quickly and effectively to financial shocks. The judicious application of macroprudential policies by national and international authorities in G7 countries is critical in determining the appropriate policy stance for their respective nations. In this process, the XGBoost method and SHAP values proposed in this paper can serve various purposes. Finally, an additional advantage of this method is that the nature of vulnerability can also be determined depending on the characteristics associated with the probability of a particular crisis. This capacity to discern between policy instruments, based on their relative appropriateness in different contexts, positions this method as a valuable tool for decision-making processes within macroprudential frameworks.