



UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CENTRO TECNOLÓGICO – CTC  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA E GESTÃO DO  
CONHECIMENTO

Renato Salvador Coutinho

**Extração de conhecimento em bases de dados por meio da aplicação de  
*Machine Learning*: um modelo de Sistema de Alerta Precoce (EWS) para crises  
financeiras**

Florianópolis  
2024

Renato Salvador Coutinho

**Extração de conhecimento em bases de dados por meio da aplicação de  
*Machine Learning*: um modelo de Sistema de Alerta Precoce (EWS) para crises  
financeiras**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento da Universidade Federal de Santa Catarina para a obtenção do título de Mestre em Engenharia do Conhecimento

Orientador: Prof. Paulo Maurício Selig, Dr.  
Coorientador: Prof. Fernando Alvaro Ostuni Gauthier, Dr.  
Coorientador externo: Prof. Aran B. Tcholakian Morales, Dr.

Florianópolis

2024

#### Ficha de identificação da obra

Coutinho, Renato Salvador

Extração de conhecimento em bases de dados por meio da aplicação de Machine Learning: um modelo de Sistema de Alerta Precoce (EWS) para crises financeiras / Renato Salvador Coutinho; orientador, Paulo Maurício Selig; coorientador, Fernando Alvaro Ostuni Gauthier, coorientador, Aran B. Tcholakian Morales, 2024.

115 p.

Dissertação (mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento, Florianópolis, 2024.

Inclui referências.

1. Engenharia e Gestão do Conhecimento. 2. Inteligência Artificial. 3. Machine Learning. 4. Early Warning Systems. 5. Crises Financeiras. I. Selig, Paulo Maurício. II. Gauthier, Fernando Alvaro Ostuni. III. Morales, Aran B. Tcholakian IV. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento. V. Título.

Renato Salvador Coutinho

**Extração de conhecimento em bases de dados por meio da aplicação de *Machine***

***Learning***: um modelo de Sistema de Alerta Precoce (EWS) para crises financeiras

O presente trabalho em nível de Mestrado foi avaliado e aprovado, em 22 de março de 2024, pela banca examinadora composta pelos seguintes membros:

Prof. José Leomar Todesco, Dr.  
Universidade Federal de Santa Catarina

Prof. Denilson Sell, Dr.  
Universidade Federal de Santa Catarina

Prof. Claudio Henrique da Silveira Barbedo, Dr.  
Instituto Brasileiro de Mercado de Capitais - IBMEC

Certificamos que esta é a versão original e final do trabalho de conclusão que foi julgado adequado para obtenção do título de Mestre em Engenharia e Gestão do Conhecimento.

---

Prof. Roberto Carlos dos S. Pacheco, Dr.  
Coordenação do Programa de Pós-Graduação

---

Prof. Paulo Maurício Selig, Dr.  
Orientador

Florianópolis, 2024.

Este trabalho é dedicado a meus pais, que sempre acreditaram no poder transformador da educação, a minha esposa e a minha filhinha, que abdicaram de tempo de convívio para que o objetivo fosse alcançado.

## AGRADECIMENTOS

A Deus, que me deu o dom da vida.

A minha querida filhinha, razão e propósito de tudo, que doou parte de seu tempo de brincar e aprender para que eu pudesse brincar e aprender com esta pesquisa (papai te ama).

A minha esposa, meu principal reforço, meu *hardware* e meu *software*, minha base para enfrentar todos os desafios (e aproveitar as oportunidades), sejam físicos ou emocionais, naturais ou artificiais.

A meus pais, que me forneceram todas as técnicas de aprendizado, supervisionado ou não, e treinaram minha inteligência humana para a resolução de problemas, sejam eles, de classificação, regressão, recomendação ou outros ainda não categorizados.

A meus queridos avós, responsáveis por grande parte dos dados de treinamento de meu modelo mental e da capacidade neural instalada.

A meu orientador, que proporcionou o método de aprendizado supervisionado para resolver o problema da dissertação.

A meu coorientador externo, que disponibilizou as técnicas e ferramentas necessárias para executar a tarefa de pesquisa.

Por fim, saindo do abstrato para o concreto, do figurado para o literal, agradeço a todos os citados ou não, que estiveram a meu lado e contribuíram com seu esforço pessoal para a realização deste trabalho.

*Solving big problems is easier than solving little problems. (PAGE, 2008)*

## RESUMO

As causas potenciais das crises financeiras e seus efeitos na vida dos cidadãos suscitam um elevado interesse da comunidade acadêmica e de bancos centrais no sentido de detectar sua ocorrência suficientemente cedo para possibilitar atuação tempestiva. Dada a relevância do tema, este trabalho se propõe a investigar o apoio à sinalização precoce de possíveis crises financeiras sistêmicas. Entretanto, uma das principais dificuldades em sua detecção precoce reside na pequena amostra de observações de crises financeiras. Por outro lado, técnicas de *Machine Learning* se destacam pela capacidade em lidar com não-linearidades, bem como interações complexas em conjuntos de dados limitados, para descobrir padrões em dados financeiros, que podem ser difíceis de identificar por meio de abordagens tradicionais. Nesse sentido, este estudo se baseia na Engenharia do Conhecimento e, mais especificamente, na aplicação das referidas técnicas, para propor um modelo de Sistema de Alerta Precoce (EWS) para crises financeiras a partir da extração do conhecimento de bases de dados. Para seu desenvolvimento, a *Design Science Research* (DSR) propicia abordagem metodológica que fornece validade científica aos resultados da pesquisa, porém com o enfoque em construir artefatos com aplicação prática. A pesquisa envolve uma revisão de escopo sobre EWSs para crises financeiras, seguida de outra revisão que aborda a aplicação de técnicas de *Machine Learning* nesse contexto. Com base nas evidências encontradas na literatura científica e na prática dos órgãos do sistema financeiro global, identifica-se uma abrangente base de dados (*JSTDatabase*) e o algoritmo *Random Forest* como componentes essenciais para integrar o modelo. Os experimentos realizados demonstraram que o modelo proposto, denominado *InCrAISys*, alcança elevada acurácia e precisão na previsão de crises financeiras segundo as métricas de eficácia aplicadas. Os resultados observados enfatizam o crescimento do crédito, a curva de juros e a taxa de serviço da dívida como atributos chave para previsão de crises financeiras. Além disso, a utilização de valores de *Shapley* fornece parâmetros relevantes sobre a medida em que cada atributo influencia determinado resultado, o que favorece a interpretabilidade do modelo. Finalmente, esta pesquisa avança nos estudos de construção e aplicação de soluções da Engenharia do Conhecimento nas organizações, mais especificamente na extração do conhecimento com o intuito de fornecer subsídios para tomadas de decisões mais fundamentadas e assertivas.

**Palavras-chave:** Gestão do Conhecimento; Engenharia do Conhecimento; Inteligência Artificial; *Machine Learning*; *Early Warning Systems*; Crises Financeiras.

## ABSTRACT

The potential causes of financial crises and their effects on citizens' lives generate significant interest among the academic community and central banks in detecting their occurrence early enough to enable timely action. Given the relevance of the topic, this work proposes to investigate the support for early signaling of possible systemic financial crises. However, one of the main challenges in their early detection lies in the small sample of financial crisis observations. On the other hand, Machine Learning techniques are particularly noted for their ability to deal with non-linearities, as well as complex interactions in limited data sets, to discover patterns in financial data that may be difficult to identify through traditional approaches. In this regard, this study is based on Knowledge Engineering and, more specifically, on the application of these techniques to propose an Early Warning System (EWS) model for financial crises from the extraction of knowledge from databases. For its development, Design Science Research (DSR) provides a methodological approach that lends scientific validity to the research outcomes, focusing on building artifacts with practical applications. The research involves a scope review of EWSs for financial crises, followed by another review addressing the application of Machine Learning techniques in this context. Based on evidence found in scientific literature and the practices of global financial system organizations, a comprehensive database (JSTDatabase) and the Random Forest algorithm are identified as essential components to integrate the model. The experiments conducted demonstrated that the proposed model, named InCrAISys, achieves high accuracy and precision in predicting financial crises according to the applied efficacy metrics. The observed results highlight credit growth, yield curve, and the debt service ratio as key attributes for predicting financial crises. Furthermore, the use of Shapley values provides relevant parameters on the extent to which each attribute influences a particular outcome, enhancing the model's interpretability. Finally, this research advances the studies on the construction and application of Knowledge Engineering solutions in organizations, more specifically in knowledge extraction intended to support more informed and assertive decision-making.

**Keywords:** Knowledge Management; Knowledge Engineering; Artificial Intelligence; Machine Learning; Early Warning Systems; Financial Crises.

## LISTA DE FIGURAS

Figura 1 - Fases <i>Knowledge-Discovery in Databases</i> (KDD) .....	35
Figura 2 - Filtro de <i>spam</i> .....	36
Figura 3 - Previsão por meio de regressão .....	37
Figura 4 - Classificação (esquerda) x <i>Clustering</i> (direita).....	37
Figura 5 - Regressão Logística .....	38
Figura 6 - Interpretabilidade Árvore de Decisão .....	39
Figura 7 - SVM e PCA.....	40
Figura 8 - Aprendizado por reforço.....	41
Figura 9 - <i>Multilayer Perceptron</i> – MLP .....	42
Figura 10 - Agregação <i>bootstrap</i> ( <i>Bagging</i> ) .....	43
Figura 11 - <i>AdaBoost</i> .....	45
Figura 12 - <i>Stacked Generalization</i> .....	45
Figura 13 - Mapa dos autores e suas interconexões.....	50
Figura 14 - Mapa das principais palavras-chave e suas interconexões .....	50
Figura 15 - Visão temporal dos indicadores .....	53
Figura 16 - Rede bibliométrica de organizações .....	62
Figura 17 - Representação do modelo .....	78
Figura 18 - Modelo <i>Orange</i> .....	84
Figura 19 - Seleção de atributos .....	86

## LISTA DE QUADROS

Quadro 1 - Teses e dissertações do EGC.....	22
Quadro 2 - Matriz de confusão .....	47
Quadro 3 - Síntese dos dados.....	51
Quadro 4 - Quantidade de resultados primários da busca .....	64
Quadro 5 - Quadro analítico .....	65
Quadro 6 - Descrição dos campos da base .....	79
Quadro 7 - Hiperparâmetros <i>Random Forest</i> .....	88

## LISTA DE TABELAS

Tabela 1 - Resumo dos indicadores de alerta anteriores a 2008 .....	32
Tabela 2 - Performance das técnicas de ML .....	82
Tabela 3 - Desempenho do modelo .....	90
Tabela 4 - Matriz de confusão dos experimentos .....	91
Tabela 5 - <i>Top 5</i> fatores de influência na previsão de crises .....	93

## LISTA DE GRÁFICOS

Gráfico 1 - Métodos X indicadores .....	54
Gráfico 2 - Distribuição das amostras ao longo dos anos .....	55
Gráfico 3 - Explicação do modelo para previsão da classe Crise.....	92

## LISTA DE ABREVIATURAS E SIGLAS

ANN	<i>Artificial Neural Network</i> – Redes Neurais Artificiais
AUC	<i>Area Under the ROC Curve</i>
BCB	Banco Central do Brasil
BIS	<i>Bank for International Settlements</i>
DSR	<i>Design Science Research</i>
EBSE	Engenharia de <i>Software</i> Baseada em Evidências
EGC	Engenharia e Gestão do Conhecimento
EPB	<i>Evidence-Based Policy</i> - Políticas Públicas Baseadas em Evidências
EWA	<i>Exponentially Weighted Average</i>
EWS	<i>Early Warning System</i> - Sistema de Alerta Precoce
FMI	Fundo Monetário Internacional
FSB	<i>Financial Stability Board</i>
GL	<i>Grey Literature</i>
IMF	<i>International Monetary Fund</i>
InCrAISys	<i>AI System to Early Indicate Financial Crisis</i>
JBI	Instituto Joanna Briggs
JSTDatabase	<i>Jordà-Schularick-Taylor Macrohistry Database</i>
KDD	<i>Knowledge Discovery in Databases</i>
LLMs	Large Language Models
MaRs	<i>Macroprudential Research Network</i>
ML	<i>Machine Learning</i>
MLR	<i>Multivocal Literature Review</i>
NTS	<i>Nested Time-Series</i>
OECD	Organização para a Cooperação e Desenvolvimento Econômico
PCA	<i>Principal Component Analysis</i>
PCC	População, Conceito e Contexto
PIB	Produto Interno Bruto
PRISMA	<i>Preferred Reporting Items for Systematic Reviews and Meta-Analyses</i>
ROC	<i>Receiver Operating Characteristic</i>
RF	<i>Random Forest</i>

SHAP	<i>SHapley Additive exPlanations</i>
SMOTE	<i>Synthetic Minority Over-sampling Technique</i>
SVM	<i>Support Vector Machines</i>
UE	União Europeia

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>17</b>
1.1	CARACTERIZAÇÃO DO PROBLEMA .....	19
1.2	OBJETIVOS .....	19
<b>1.2.1</b>	<b>Objetivo Geral</b> .....	<b>19</b>
<b>1.2.2</b>	<b>Objetivos Específicos</b> .....	<b>20</b>
1.3	ESCOPO DO TRABALHO .....	20
1.4	ADERÊNCIA AO EGC .....	21
1.5	ESTRUTURA DO TRABALHO .....	23
<b>2</b>	<b>PROCEDIMENTOS METODOLÓGICOS</b> .....	<b>25</b>
2.1	ABORDAGEM .....	25
2.2	PROCESSO DE PESQUISA .....	26
<b>2.2.1</b>	<b>Identificação do problema e motivação</b> .....	<b>26</b>
<b>2.2.2</b>	<b>Definição dos objetivos para uma solução</b> .....	<b>26</b>
<b>2.2.3</b>	<b>Design e desenvolvimento</b> .....	<b>27</b>
<b>2.2.4</b>	<b>Demonstração</b> .....	<b>27</b>
<b>2.2.5</b>	<b>Avaliação</b> .....	<b>28</b>
<b>2.2.6</b>	<b>Comunicação</b> .....	<b>28</b>
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>29</b>
3.1	EWS E CRISES FINANCEIRAS SISTÊMICAS .....	30
3.2	TÉCNICAS DE MACHINE LEARNING .....	34
<b>3.2.1</b>	<b>Tarefas</b> .....	<b>36</b>
<b>3.2.2</b>	<b>Abordagens</b> .....	<b>38</b>
<b>3.2.3</b>	<b>Métricas de avaliação</b> .....	<b>46</b>
<b>4</b>	<b>ESTADO DO CONHECIMENTO</b> .....	<b>48</b>
4.1	EWSs PARA CRISES FINANCEIRAS .....	48
<b>4.1.1</b>	<b>Resultados</b> .....	<b>49</b>
<b>4.1.2</b>	<b>Discussão</b> .....	<b>55</b>
<i>4.1.2.1</i>	<i>Sumário das evidências</i> .....	<i>56</i>
<i>4.1.2.1.1</i>	<i>Padrões, índices e indicadores</i> .....	<i>56</i>
<i>4.1.2.1.2</i>	<i>Métodos, técnicas e ferramentas</i> .....	<i>57</i>
<i>4.1.2.1.3</i>	<i>Tendências</i> .....	<i>58</i>
<i>4.1.2.2</i>	<i>Limitações</i> .....	<i>58</i>
<i>4.1.2.3</i>	<i>Considerações</i> .....	<i>59</i>

4.2	USO DE ML EM EWSs PARA CRISES FINANCEIRAS .....	60
<b>4.2.1</b>	<b>Resultados .....</b>	<b>61</b>
<b>4.2.2</b>	<b>Discussão.....</b>	<b>67</b>
4.2.2.1	<i>Sumário das evidências .....</i>	67
4.2.2.1.1	<i>Machine Learning</i> x técnicas tradicionais .....	68
4.2.2.1.2	Modelo de EWS.....	70
4.2.2.1.3	Causa e efeito .....	72
4.2.2.2	<i>Limitações .....</i>	73
4.2.2.3	<i>Considerações.....</i>	75
<b>5</b>	<b>APRESENTAÇÃO DO MODELO .....</b>	<b>77</b>
5.1	COMPONENTES DO MODELO.....	77
<b>5.1.1</b>	<b>Base de dados .....</b>	<b>78</b>
<b>5.1.2</b>	<b>Atributos.....</b>	<b>81</b>
<b>5.1.3</b>	<b>Técnica de <i>Machine Learning</i>.....</b>	<b>82</b>
<b>5.1.4</b>	<b>Método de explicação do modelo .....</b>	<b>83</b>
5.2	CONSTRUÇÃO DO MODELO .....	83
<b>5.2.1</b>	<b>Extração e preparação dos dados .....</b>	<b>85</b>
<b>5.2.2</b>	<b>Engenharia de atributos.....</b>	<b>87</b>
<b>5.2.3</b>	<b>Treinamento do modelo .....</b>	<b>88</b>
<b>5.2.4</b>	<b>Calibração dos hiperparâmetros.....</b>	<b>88</b>
<b>5.2.5</b>	<b>Teste e validação do modelo.....</b>	<b>89</b>
5.3	CONSIDERAÇÕES .....	89
<b>6</b>	<b>DEMONSTRAÇÃO E AVALIAÇÃO .....</b>	<b>90</b>
6.1	DESEMPENHO DO MODELO .....	90
6.2	IMPORTÂNCIA E SIGNIFICÂNCIA DOS ATRIBUTOS.....	91
6.3	ADEQUAÇÃO DO MODELO AO PROBLEMA.....	94
<b>7</b>	<b>CONCLUSÃO .....</b>	<b>95</b>
	<b>REFERÊNCIAS .....</b>	<b>99</b>
	<b>APÊNDICE A – Resumo do protocolo da revisão de escopo .....</b>	<b>108</b>
	<b>APÊNDICE B – Seleção das fontes da revisão de escopo.....</b>	<b>109</b>
	<b>APÊNDICE C – Resumo do protocolo da MLR.....</b>	<b>110</b>
	<b>APÊNDICE D – Seleção das fontes de evidência da MLR.....</b>	<b>111</b>
	<b>APÊNDICE E – Script SMOTE.....</b>	<b>112</b>
	<b>ANEXO A – <i>Widget Rank (Orange Data Mining)</i> .....</b>	<b>113</b>

## 1 INTRODUÇÃO

O colapso de algumas moedas, que ocorreu entre o final da década de 80 e início dos anos 2000, gerou efeitos devastadores sobre os sistemas financeiros de países emergentes, principalmente asiáticos (Eichengreen *et al.*, 1995; Kaminsky & Reinhart, 1999). Posteriormente, a crise das empresas de tecnologia nos Estados Unidos despertou uma preocupação maior nas autoridades governamentais sobre processos de instabilidade financeira e seus efeitos (Bussiere & Fratzscher, 2006).

Entretanto, foi a partir da Crise do *Subprime*, que as causas potenciais e os sintomas das crises sistêmicas do mercado financeiro despertaram maior interesse da comunidade de bancos centrais e de acadêmicos (Reinhart & Rogoff, 2009). Tal preocupação pode ter uma de suas raízes no custo fiscal médio incorrido pelos governos para lidar com crises financeiras sistêmicas, que, conforme a estimativa de Laeven & Valencia (2018), em países de alta renda equivale a cerca de 6,7% do Produto Interno Bruto (PIB), enquanto em países de renda média e baixa monta cerca de 10%.

Conquanto crises financeiras, à primeira vista, pareçam eventos aleatórios, geralmente dão sinais prévios de que vão ocorrer, todavia, identificar um conjunto confiável de padrões comuns à sua ocorrência precocemente não é tarefa simples por vários motivos. Primeiramente, há um conjunto relativamente limitado de crises observadas, o que dificulta uma modelagem robusta e estatisticamente relevante, ademais, os indicadores de crise podem alcançar *status* de alerta quando já é tarde demais para intervir (Alessi & Detken, 2018).

Cabe ressaltar que os instrumentos das políticas macroprudenciais, cujo objetivo consiste em limitar o risco sistêmico<sup>1</sup>, não geram efeitos no curto prazo. Conseqüentemente, as autoridades monetárias necessitam que os sinais de alerta sejam detectados com antecedência para que possam implementar as medidas de prevenção destinadas a reduzir a probabilidade ou atenuar os impactos de riscos potenciais advindos de eventuais crises sistêmicas (Blundell-Wignall & Roulet, 2014).

---

<sup>1</sup> Relatório conjunto *Macroprudential Policy Tools and Frameworks* do *Financial Stability Board* (FSB), Fundo Monetário Internacional (FMI) e do *Bank for International Settlements* (BIS) de 27 de outubro de 2011.

Em uma revisão sistemática de literatura, Khankeh *et al.* (2019) destacam o papel cada vez mais reconhecido dos Sistemas de Alerta Precoce (*Early Warning Systems* - EWSs) na gestão de risco de desastres, na minimização de perdas econômicas de eventos como terremotos e tsunamis e em várias ações destinadas a reduzir riscos. A propósito, a Organização para a Cooperação e Desenvolvimento Econômico – OECD (2017) assevera que os avanços tecnológicos levaram a melhorias significativas nos EWSs e acrescentam que esses sistemas podem apoiar a tomada de decisões dos governos a partir da detecção automática de anomalias e previsão de possíveis crises que exijam sua atuação.

Apesar da relevância e emergência do tema de estudo, alguns autores, como é o caso de Klopotan *et al.* (2018), observam que a maior parte dos EWSs para previsão de crises financeiras foi desenvolvida após 2010. Esse achado evidencia a natureza incipiente e pouco explorada da literatura sobre esses sistemas, observação corroborada por Guru (2016) e Galán & Mencía (2021).

A formação de uma crise financeira deve ser vista a partir de uma série de mudanças em um sistema complexo em todos os sentidos, o que vai se agravando na medida em que o número de possíveis fatores intervenientes aumenta. Além disso, algumas crises podem ser geradas por heterogeneidades de mercado, cuja detecção e exploração, particularmente por perspectivas capazes de capturar e analisar dados não estruturados e suas relações em tempo real, são apontadas por Herwatz & Kholodilin (2014) como uma possível fonte de trabalhos futuros.

De acordo com Bajari *et al.* (2015), previsões realizadas por meio de técnicas de *Machine Learning* (ML) podem ser mais precisas que aquelas derivadas de abordagens convencionais. Apesar da relativamente pequena amostra de observações de crise, existe a perspectiva de que estas ferramentas possam ser capazes de descobrir relacionamentos, inclusive entre dados não estruturados, que podem ser difíceis de identificar usando técnicas clássicas.

Adicionalmente, ferramentas de ML têm o potencial de aprender por meio associações de altos volumes de dados, sem a dependência de programação explícita (Goodfellow *et al.*, 2016). Finalmente, vários estudos têm apontado que essas abordagens apresentam melhor desempenho em relação aos EWSs baseados em métodos estatísticos tradicionais para previsão de crises financeiras (e.g. Alessi & Detken, 2018; Tanaka, *et al.*, 2016; Holopainen & Sarlin, 2017).

## 1.1 CARACTERIZAÇÃO DO PROBLEMA

Todos esses fatores devidamente ponderados conduzem à formulação da seguinte questão norteadora: Como apoiar a sinalização precoce de possíveis crises financeiras sistêmicas?

## 1.2 OBJETIVOS

Nas seções abaixo estão descritos o objetivo geral e os objetivos específicos desta dissertação.

### 1.2.1 Objetivo Geral

No campo da economia, Morgan & Morrison (1999) relatam que, desde os primeiros estágios da pesquisa, a prática se baseia na construção e utilização de modelos. A esse respeito, na metodologia *CommonKADS* (Schreiber *et al.*, 2000), um modelo é considerado uma representação abstrata e estruturada de algum aspecto do conhecimento.

A propósito, os autores da metodologia situam da seguinte forma a questão da modelagem no campo da Engenharia do Conhecimento:

*Today, knowledge engineering is approached as a modelling activity. A model is a purposeful abstraction of some part of reality. Modelling is constructing a good description (that is, good enough for your purpose) of only a few aspects of knowledge and leaving out the rest. (Schreiber et al., 2000, p. 15)*

Nessa linha, o objetivo geral da presente pesquisa para abordar o problema é propor um modelo de Sistema de Alerta Precoce (EWS) para crises financeiras a partir da extração de conhecimento de bases de dados por meio de técnicas de *Machine Learning*.

### 1.2.2 Objetivos Específicos

Para a consecução do objetivo geral, foram estabelecidos os seguintes objetivos específicos:

- a) Identificar um conjunto confiável de padrões comuns às crises financeiras sistêmicas, que apresentem potencial para sinalizar sua possibilidade de ocorrência precocemente;
- b) Selecionar técnicas de ML capazes de extrair conhecimento de padrões e relações não-lineares em dados financeiros;
- c) Obter base de dados financeira que contemple as variáveis previamente identificadas.

### 1.3 ESCOPO DO TRABALHO

Este trabalho reconhece a relevância de todos os temas afetos ao campo de conhecimento da economia e das finanças, entretanto, se concentra em estudar as crises financeiras sistêmicas, cujo foco de preocupação dos bancos centrais está direcionado à previsão de deflagração. Dentro desse escopo de estudo, a pesquisa está delimitada em identificar padrões comuns às crises que apresentem potencial para sinalizar sua possibilidade de ocorrência.

Quanto aos EWSs, a pesquisa se limita a estudar os sistemas aplicados à previsão de crises financeiras e a aplicação de técnicas de ML. A esse respeito, as ferramentas já apresentam um estado avançado de maturidade na descoberta de padrões em bases de dados numéricas, ademais já há muito trabalho desenvolvido em relação à codificação, que não faz parte do escopo deste trabalho.

Por fim, a solução desenvolvida se utiliza de técnicas de ML para extração de conhecimento a partir da base de dados obtida e aprimorada ao longo da pesquisa visando sinalizar antecipadamente a ocorrência de crises financeiras. Nesse sentido, o produto do trabalho não é um sistema, mas um modelo composto das aludidas técnicas associadas à base de dados e às variáveis identificadas para prover antecipadamente alertas de possíveis crises e servir de subsídio para a tomada de decisão e atuação tempestiva das autoridades monetárias.

## 1.4 ADERÊNCIA AO EGC

Esta dissertação trata da extração de conhecimento em bases de dados para buscar padrões ou índices que sinalizem antecipadamente a possibilidade de ocorrência de crises financeiras por meio da utilização de ML. Como tal, está inserida na área de concentração Engenharia do Conhecimento e na linha de pesquisa Engenharia do Conhecimento Aplicada às Organizações.

No Programa de Pós-Graduação em Engenharia e Gestão do Conhecimento (EGC), essa linha trata da concepção, desenvolvimento e implantação de soluções da Engenharia do Conhecimento em organizações públicas e privadas. Nesse contexto, percebe-se o conhecimento como “processo e produto tangível ou intangível efetivado na relação entre pessoas e agentes não humanos para a geração de valor”, considerada no EGC, como a visão cognitivista de conhecimento, definição adotada pela área de Engenharia do Conhecimento.

A Engenharia do Conhecimento tem sua origem em um ramo da Inteligência Artificial que objetiva estudar métodos e técnicas para extração, manipulação e classificação do conhecimento como apoio para a construção de sistemas de Gestão do Conhecimento (Nazário *et al.*, 2014). Davenport e Prusak (1998) definem conhecimento como uma combinação de experiências, valores, informação contextual e *insight*, que fornece uma estrutura para avaliação e incorporação de novas experiências e informações.

Resumidamente, o tema objeto da pesquisa, circunscrito ao amplo campo da Engenharia do Conhecimento, é a extração de conhecimento de bases de dados para identificar sinais comuns às crises financeiras capazes de detectar precocemente sua ocorrência. Em que pese a combinação de saberes das áreas de Economia, Finanças e Tecnologia da Informação e Comunicação, presente no estudo em tela, seu diferencial para o EGC é a abordagem de Gestão do Conhecimento aplicada ao estudo dos padrões relacionados às crises financeiras e sua identificação por meio de ferramentas de Engenharia do Conhecimento, notadamente, de Inteligência Artificial e, mais especificamente, da aplicação de técnicas de *Machine Learning*.

No âmbito do EGC, foram encontradas 6 dissertações e 1 tese de doutorado que guardam afinidade com o tema deste trabalho. No quadro a seguir, estão destacados os trabalhos considerados de contexto mais próximo ao desta dissertação.

Quadro 1 - Teses e dissertações do EGC

<b>Autor</b>	<b>Ano</b>	<b>Título</b>	<b>Objetivo</b>
CECI, F.	2015	Um modelo baseado em casos e ontologia para apoio à tarefa intensiva em conhecimento de classificação com foco na análise de sentimentos.	Desenvolver um modelo em que seja possível representar o conhecimento de domínio, bem como, armazenar e recuperar raciocínios passados para suportar a tarefa de classificação voltada à polarização de conteúdo não-estruturado.
FAGUNDES, V. B.	2018	Proposta de uso de Engenharia do Conhecimento para revisão sistemática.	Propor um modelo de Sistema Baseado em Conhecimento para apoio ao processo de Revisão Sistemática de Literatura.
ALVAREZ, G. M.	2018	Análise de agrupamentos e mineração de opinião como suporte à gestão de ideias.	Propor um método para suporte e avaliação de ideias baseado em métodos e técnicas de Engenharia do Conhecimento.
FARACO, F.M.	2020	Modelo de conhecimento baseado em tópicos de acórdãos para suporte à análise de petições iniciais.	Construir um modelo de conhecimento a partir da extração de tópicos sobre julgados (acórdãos) de forma a suportar a tarefa de análise das petições iniciais.
BLANCK, H.	2020	Capital de risco e startups: modelo de suporte na tomada de decisão com aprendizado de máquina.	Propor um modelo de análise de investimentos em <i>Startups</i> via fundos de capital de risco por meio de algoritmos de aprendizado de máquina.
SILVA, S. N.	2021	Modelo de Engenharia do Conhecimento para a evasão no ensino superior.	Criar um modelo de evasão como forma de compartilhamento do conhecimento, suportado por uma ontologia e dados abertos, sendo um norteador na análise de evasão na IES.
KASTER, G. B.	2021	<i>Framework</i> Conceitual Baseado em Aprendizagem de Máquina Supervisionada para Concepção de Sistemas Judiciais de Agentes Inteligentes.	Propor um <i>framework</i> conceitual baseado em aprendizagem de máquina supervisionada (FCAM) para concepção de sistemas de agentes inteligentes.

Fonte: Elaborado pelo autor, com base no banco de teses e dissertações do EGC/UFSC

Pode-se depreender, pela análise do Quadro 1, que o interesse no estudo de Inteligência Artificial em geral e ML em particular vem crescendo no EGC ao longo dos últimos anos com o objetivo principal de proposição de modelos, métodos e *frameworks* que se utilizam destas técnicas para apoiar a tomada de decisão em alguma medida. Cabe ressaltar ainda que, dentre as pesquisas relacionadas, há um trabalho que guarda contexto de aplicação no mesmo setor da presente pesquisa, a saber, na área financeira e todos abordam ferramentas de ML, embora com níveis de profundidade e de utilização diferentes.

Observando-se o histórico de trabalhos do EGC, nota-se que a presente dissertação traz como contribuição específica, a extração do conhecimento relacionado a crises financeiras. Outrossim, agrega ao modelo proposto o uso de ferramentas de Engenharia do Conhecimento, particularmente, de *Machine Learning*, cuja eficácia para descoberta de padrões em bases de dados numéricas já é comprovada.

Finalmente, esta dissertação pode subsidiar novas pesquisas que tenham como objetivo abordar o conhecimento na área econômico-financeira, especificamente, aquelas relacionadas a crises financeiras. Ademais, o trabalho pode servir de base para o emprego de ferramentas de ML para extração de padrões em bases numéricas possibilitando o avanço dos estudos na área de Engenharia do Conhecimento.

## 1.5 ESTRUTURA DO TRABALHO

A presente dissertação está organizada de modo a refletir o processo sistemático e iterativo adotado na pesquisa, seguindo a abordagem da *Design Science Research* (DSR). A seguir, a estrutura do trabalho segue descrita com base no conteúdo de cada capítulo e como ele se alinha às etapas do trabalho.

O capítulo 1 (Introdução) apresenta o contexto da pesquisa, incluindo a identificação do problema e a motivação para o estudo, bem como os objetivos gerais e específicos da dissertação. O presente capítulo explora os fundamentos do trabalho, delineando a questão de pesquisa e seu escopo.

No capítulo 2 a escolha da DSR como procedimento metodológico adotado na pesquisa é explicada a partir de sua adequação para o desenvolvimento do modelo proposto. Adicionalmente, o processo de pesquisa é relatado por meio de sua abordagem e suas fases de acordo com o contexto do trabalho.

O capítulo 3 aproxima-se do tema de pesquisa por meio da literatura existente, destacando os conceitos fundamentais para sua compreensão, quais sejam: EWS, crises financeiras sistêmicas e técnicas de *Machine Learning*. Além disso, foca na aplicação de EWSs para crises financeiras e no potencial de ML para a detecção de padrões preditivos em dados financeiros, apresentando as principais questões e características destas técnicas necessárias para o desenvolvimento do modelo.

O capítulo 4 revisa os estudos anteriores relacionados ao tema e aborda as contribuições relevantes para a área de pesquisa, estabelecendo o estado atual do conhecimento sobre EWSs para crises financeiras e a utilização de técnicas de ML nesses sistemas. Esse capítulo discute as tendências e limitações tanto da literatura acadêmica quanto da prática das autoridades monetárias e órgãos que fazem parte do sistema financeiro global, com o intuito de identificar lacunas e oportunidades que a presente dissertação visa explorar.

No capítulo 5, detalha-se, a partir de suas etapas e componentes, o *design* e o desenvolvimento do modelo construído para atender aos objetivos específicos da pesquisa. Por seu turno, o capítulo 6 discorre sobre a aplicação do modelo *InCrAISys* ao conjunto de dados financeiros selecionado e transformado, demonstrando sua utilidade prática e performance na sinalização de crises financeiras com base em métricas específicas.

Por fim, a conclusão encerra a dissertação com um resumo dos principais achados da pesquisa, a contribuição do trabalho para o campo de estudo, as limitações enfrentadas e sugestões para pesquisas futuras. Esse capítulo reflete sobre o sucesso do modelo em atender os objetivos da pesquisa e sua potencial aplicabilidade como solução de Engenharia do Conhecimento nas organizações, mais especificamente na extração do conhecimento com o intuito de fornecer subsídios para tomadas de decisões mais fundamentadas e assertivas.

## 2 PROCEDIMENTOS METODOLÓGICOS

De acordo Lacerda *et al.* (2013), a *Design Science* se encarrega de conceber e validar sistemas que ainda não existem, por meio da criação, combinação ou alteração de produtos, processos, *softwares* ou métodos com o intuito de melhorar circunstâncias ou condições existentes. Tendo em vista que este trabalho parte de uma questão prática proveniente da identificação da necessidade dos bancos centrais de prever crises financeiras antecipadamente com o intuito de atuar de forma tempestiva com medidas macroprudenciais para reduzir sua probabilidade e impacto, identificou-se a *Design Science Research* (DSR) como o procedimento metodológico adequado para seu desenvolvimento.

No âmbito da pesquisa em Sistemas de Informação, March & Storey (2008) enfatizam que a DSR requer como contribuição o desenvolvimento e apresentação de artefatos (construtos, modelos, métodos ou instanciações) capazes de abordar o problema em questão. Segundo Hevner *et al.* (2004), a DSR se destaca por materializar inovações que refletem ideias, práticas e capacidade técnica, que, apesar de não se converterem necessariamente em sistemas, podem servir de base para seu *design* e implementação.

O emprego da DSR provê abordagem metodológica rigorosa e apropriada que fornece validade científica aos resultados da pesquisa, porém com o enfoque de construir artefatos com aplicação prática. O principal produto desse tipo de pesquisa é a criação de um *design* genérico inovador, testado, compreendido e documentado, com o intuito de estabelecer validade pragmática (Van Aken *et al.*, 2016).

### 2.1 ABORDAGEM

Com base em um determinado problema de domínio, a DSR gera um artefato, que deve ser avaliado segundo critérios de utilidade ou valor. (Dresch, *et al.*, 2015). O trabalho foi conduzido a partir de um problema organizacional relevante por um pesquisador especialista, com dados reais e guiado por uma abordagem metodológica científica, porém sem intervenção direta nas práticas profissionais.

A DSR não culmina necessariamente na produção de sistemas de informação prontos para uso prático, mas sim na geração de conhecimento explícito a partir do conhecimento tácito contido em problemas práticos. A referida metodologia apresenta variações em sua abordagem e neste trabalho optou-se por utilizar aquela proposta por Peffers *et al.* (2007), citada de forma recorrente na literatura.

## 2.2 PROCESSO DE PESQUISA

O processo da metodologia é estruturado em seis atividades sequenciais e iterativas, com a ressalva de que sua aplicação pode não se iniciar obrigatoriamente na primeira. A seguir, estão relacionadas as etapas e uma descrição sucinta de cada uma, bem como a aplicação nesta pesquisa.

### 2.2.1 Identificação do problema e motivação

Esta etapa inclui a definição do problema de pesquisa específico e justificativa do valor de uma solução. Os recursos necessários para essa atividade incluem o conhecimento do estado do problema e a importância de sua solução.

No contexto deste trabalho, a identificação do problema foi realizada por meio de uma revisão de escopo da literatura sobre EWSs para crises financeiras sistêmicas, utilizando o protocolo *PRISMA-ScR* (Tricco *et al.*, 2018). A partir dessa revisão, seguindo o protocolo estabelecido por Garousi *et al.* (2019), foi realizada outra revisão para analisar a prática dos órgãos do sistema financeiro global em relação ao uso de ML em EWSs.

### 2.2.2 Definição dos objetivos para uma solução

Este passo consiste na inferência dos objetivos de uma possível solução a partir da definição do conhecimento do problema e do que é possível e viável. Os recursos necessários para isso incluem o conhecimento do estado dos problemas e das soluções atuais, se houver, bem como de sua eficácia.

A revisão de literatura forneceu *insights* sobre as limitações dos EWSs tradicionais e o potencial do ML para a previsão de crises financeiras. Com base na identificação do problema e da análise das soluções existentes, foram estabelecidos os objetivos da pesquisa listados na seção 1.2 deste trabalho.

Para alcançar o objetivo específico de identificar padrões, foram analisados os indicadores de alerta precoce utilizados em EWSs existentes e revelados aqueles com maior potencial preditivo. Já o objetivo de selecionar técnicas de ML foi atingido por meio da revisão de literatura, destacando aquelas mais adequadas para lidar com as características dos dados financeiros e do problema de previsão de crises.

O objetivo de obter base de dados foi atingido pela escolha do *Jordà-Schularick-Taylor Macroeconomic Database* (Jordà *et al.*, 2017), devido ao fato de contemplar um conjunto abrangente de dados macroeconômicos e financeiros aderentes ao problema desta pesquisa. Finalmente, o artefato proposto para se alcançar o objetivo geral é um modelo de EWS baseado em técnicas de ML para extrair conhecimento de bases de dados visando identificar sinais capazes de antecipar crises financeiras.

### **2.2.3 Design e desenvolvimento**

Esta fase contempla a construção do artefato, *e.g.* construtos, modelos, métodos ou instanciações ou novas propriedades de recursos técnicos, sociais ou de informação. Os recursos necessários para passar dos objetivos ao *design* e desenvolvimento incluem o conhecimento da teoria que pode ser utilizada em uma possível solução.

A etapa parte da identificação dos componentes relacionados nos objetivos específicos (um conjunto de padrões; técnicas de ML; e base de dados), passa pela construção do modelo e se conclui com o treinamento de ferramentas de ML com potencial de lidar com o problema do estudo.

### **2.2.4 Demonstração**

Esta atividade se traduz como a prova de uso do artefato para resolver uma ou mais instâncias do problema. Os recursos necessários para a demonstração incluem o conhecimento efetivo de como usar o artefato para resolver o problema.

Nesse ponto, é demonstrada a eficácia do artefato em resolver o problema, com base no conhecimento adquirido nas fases anteriores. Essa fase é materializada por meio da simulação do modelo com o banco de dados de variáveis e indicadores encontrados para a sinalização das crises financeiras identificadas na literatura.

### 2.2.5 Avaliação

A avaliação consiste na comprovação do nível de efetividade do artefato como solução para o problema. Essa atividade envolve a comparação dos objetivos da solução com os resultados reais observados do uso do artefato na demonstração e requer conhecimento de métricas e técnicas de análise relevantes.

Essa etapa é congruente com a etapa de construção do modelo denominada “Teste e validação”. No presente estudo, esse procedimento se dá de forma empírica, por meio da aplicação de métricas de avaliação de desempenho de modelos de ML, a saber: AUC, acurácia, precisão, *recall* e F1-score.

### 2.2.6 Comunicação

A comunicação envolve a divulgação do problema e de sua importância; do artefato e de sua utilidade e novidade; do rigor de seu *design* e de sua eficácia para pesquisadores e outros públicos relevantes e requer conhecimento da cultura das disciplinas envolvidas. Para tal, além desta dissertação, poderão ser propostas divulgações dos resultados da pesquisa por meio de artigos científicos, *working papers*, ou outros meios de disseminação científica cobrindo:

1. a identificação de:
  - um conjunto confiável de padrões comuns às crises que apresentem potencial para sinalizar sua possibilidade de ocorrência;
  - técnicas de ML com potencial de utilização para resolução do problema; e
2. Aplicação do modelo *InCrAISys*.

### 3 FUNDAMENTAÇÃO TEÓRICA

De acordo com Blundell-Wignall & Roulet (2014), as primeiras referências à Política Macropudencial aconteceram em reuniões fechadas na área de supervisão bancária na década de 1970, já suas primeiras “aparições públicas” ocorreram em relatórios como o *Cross Report do Bank for International Settlements* de 1986 (BIS, 1986), onde um capítulo inteiro foi dedicado ao assunto. Porém, somente recentemente o termo ganhou mais importância, a partir das crises sistêmicas do final da década de 1990 e da Crise econômica global de 2008.

Os autores destacam a complexidade das fontes e causas de riscos sistêmicos do sistema financeiro e sugerem quatro passos básicos que os formuladores de políticas macropudenciais devem seguir, a saber: i. identificar desequilíbrios antes que se tornem um problema; ii. selecionar a ferramenta ou as ferramentas prudenciais apropriadas; iii. decidir como calibrar (dados e modelagem) e cronometrar a intervenção; e iv. coordenar esforços com todos os reguladores e supervisores. Ainda conforme o trabalho, o primeiro passo é particularmente problemático, na medida em que os fundamentos e as inovações no sistema ocorrem em um ritmo acelerado, que se torna ainda mais extremo nos mercados emergentes em geral, onde a intermediação financeira se encontra ainda nos estágios iniciais de desenvolvimento.

Esse problema em aberto, reforçado também no relatório *Macprudential Policy Tools and Frameworks*, referido anteriormente, constitui o objetivo de um EWS, que, de acordo com Berg *et al.* (1999), é constituído por uma definição precisa de crise financeira, dotado de um mecanismo de geração de previsões, que, por sua vez, inclui um conjunto de variáveis que podem ajudar a prever crises e um método sistemático para obter uma previsão a partir delas. A propósito, Frankel & Saravelos (2012) ressaltam que um dos desafios encontrados na pesquisa empírica é o fato de as definições de crise financeira e gravidade variarem significativamente.

O trabalho de Laeven & Valencia (2013) explora esse *gap* de pesquisa e define crise financeira como uma situação em que há sinais significativos de dificuldades financeiras e perdas em amplos setores do sistema financeiro. Lo Duca & Peltonen (2013) adicionam o conceito de eventos sistêmicos, *i.e.* eventos em que a instabilidade financeira se torna tão generalizada que prejudica o funcionamento do

sistema financeiro em tal magnitude que o crescimento econômico e o bem-estar sofrem materialmente.

A partir da definição de crises sistêmicas estabelecida por Laeven & Valencia (2013), Jemović & Marinković (2021) acrescentam que as pesquisas empíricas indicam que diferentes tipos de crises financeiras têm suas raízes em fraquezas semelhantes da economia ou podem ter determinantes comuns, que podem se constituir em evidências sólidas para a tomada de decisão. Abordagem que vem crescendo em importância no meio acadêmico, político e profissional a partir do conceito de Políticas Públicas Baseadas em Evidências (*Evidence-Based Policy – EPB*), que se destaca como ferramenta para tomada de decisões e formulação de políticas públicas (Davies, 2012).

De acordo com a *Encyclopedia Britannica* (Yanow, 2021), o movimento tem sua origem no Reino Unido na década de 1990 a partir de uma tendência da área da medicina que defendia que somente deveriam ser utilizadas as modalidades de tratamento baseadas em evidências experimentais. Independente do campo de pesquisa, do debate e das diversas interpretações a respeito do termo, quando se trata, por exemplo, de política macroprudencial, a abordagem se apresenta extremamente adequada (Barwell, 2013).

A tomada de decisão e a atuação com base nas evidências trazidas pelos EWSs conduzem de volta aos segundo e terceiro passos sugeridos por Blundell-Wignall & Roulet (2014), que são referidos como *macroprudential policy toolkit* no relatório conjunto do FSB, FMI e BIS (2011), onde também se encontra seu detalhamento, que não faz parte do escopo deste trabalho. Finalmente, por mais que haja um “receituário econômico” para combater os efeitos de crises, as boas práticas de governança e gestão assumem papel relevante por meio do aprimoramento e implementação de soluções que aumentem a efetividade das políticas públicas em geral e macroprudenciais no caso das autoridades monetárias.

### 3.1 EWS E CRISES FINANCEIRAS SISTÊMICAS

Bussiere & Fratzscher (2006) observaram que a sucessão de crises ocorridas na década de 1990 gerou consequências econômicas, sociais e políticas devastadoras que não se limitaram a economias individuais, mas contagiaram todo o

sistema financeiro internacional. Como resultado, os autores relatam que organizações internacionais e instituições financeiras começaram a desenvolver modelos de EWSs com o objetivo de antecipar a ocorrência de crises financeiras em determinados países, principalmente devido à possibilidade de geração de efeitos sistêmicos.

Essa tendência se intensifica a partir da crise financeira global de 2008, como se pode observar a partir do estudo de Klopota *et al.* (2018), que, em uma análise bibliométrica sobre EWSs aplicada às áreas de administração, economia e finanças observa que a maioria dos sistemas para previsão de crises financeiras foi desenvolvida após 2010. A respeito do tema, os autores afirmam não ter encontrado estudos estruturados anteriores, consideração compartilhada ainda, por Guru (2016) e Galán & Mencía (2021), que caracterizam a pesquisa na área, respectivamente, como literatura esparsa e incipiente.

Kaminsky (2003) divide os modelos que tentam explicar as crises cambiais que acometeram tanto as economias avançadas quanto os mercados emergentes a partir da década de 1970 em três gerações. A primeira e a segunda geração focam em crises puramente cambiais, enquanto a terceira cobre uma gama maior de crises a partir dos episódios ocorridos no final da década de 1990.

O tipo de crise deflagrada (cambial, bancária ou soberana) acaba determinando o conjunto de variáveis independentes utilizadas que compõem os indicadores e que por sua vez, alimentam os modelos de EWSs. Entretanto, notadamente, a partir da Crise do *Subprime*, tendo em vista a alta possibilidade de contágio observada no contexto atual de um sistema financeiro profundamente interligado, as crises financeiras sistêmicas são as que representam o maior potencial de danos e, portanto, de estudo e aplicação para EWSs, independentemente da origem. Por oportuno, não poderia ser mais atual a assertiva de Eichengreen e Portes:

*Financial crises, like contagious disease, threaten not only the host organism, namely the financial market, but the entire economic environment in which that host resides.* (Eichengreen & Portes, 1987, p. 3).

De acordo com Edison (2003), a construção de um sistema de alerta precoce para crises financeiras requer a delimitação do conceito de crise, a definição do escopo (amostra e conjunto de variáveis) e a escolha do método. Seguindo uma lógica similar, Guru (2016) estabelece como etapas a definição da noção de crise; a

elaboração de uma lista de potenciais variáveis explicativas e o estabelecimento dos limiares que definem seu comportamento como sinal de um evento normal ou de crise.

Kaminsky et. al (1998) se concentram em cerca de 20 países entre mercados emergentes e economias desenvolvidas para avaliar a evolução de uma série de variáveis macroeconômicas e financeiras em períodos de crise, que, de acordo com a abordagem de sinais desenvolvida pelos autores são traduzidas em indicadores potenciais de alerta precoce para sua ocorrência. A partir da consolidação das variáveis, os principais indicadores utilizados no estudo são classificados segundo as seguintes categorias: Conta capital; Perfil de endividamento; Conta corrente; Internacional; Outras variáveis financeiras; Setor real; Fiscal, Fatores institucionais /estruturais e Política.

Por outro lado, Guru (2016) estabelece três conjuntos (indicadores macroeconômicos, setor externo e setor financeiro), já Jemović et Marinković (2021) os dividem em externos, domésticos e financeiros. Entretanto, em uma pesquisa mais ampla, Frankel & Saravadelos (2012) consolidam os indicadores de alerta precoce significativamente relevantes encontrados na literatura antes de 2008, conforme tabela reproduzida a seguir.

Tabela 1 - Resumo dos indicadores de alerta anteriores a 2008

<i>Leading Indicator</i>	<b>KLR (1998)</b>	<b>Hawkins and Klau (2000)</b>	<b>Abiad (2003)</b>	<b>Outros</b>	<b>Total</b>
Reservas	14	18	13	5	50
Taxa de câmbio real	12	22	11	3	48
PIB	6	15	1	3	25
Crédito	5	8	6	3	22
Conta Corrente	4	10	6	2	22
Base Monetária	2	16	1	0	19
Exportação ou importação	2	9	4	2	17
Inflação	5	7	1	2	15
Retorno sobre o Patrimônio	1	8	3	1	13
Taxa de juros real	2	8	2	1	13
Composição da dívida	4	4	2	0	10
Balanço orçamentário	3	5	1	0	9
Termos de Troca	2	6	1	0	9
Contágio	1	5	0	0	6
Política / legal	3	2	1	0	6
Fluxo de Capital	3	0	0	0	3
Dívida Externa	0	1	1	1	3
Número de estudos	28	28	20	7	83

Fonte: Frankel & Saravadelos (2012, p. 218)

Outra questão relevante para o estudo sobre EWSs é a escolha do método, cuja literatura tem sua raiz, predominantemente, nos trabalhos de Kaminsky et. al (1998) e Frankel & Rose (1996). Os modelos desenvolvidos pelos autores utilizam, respectivamente, a abordagem de sinais (*signaling approach*) e modelos de regressão, no estudo original, o modelo econométrico *Probit*.

Resumidamente, a abordagem de sinais consiste na observação de uma série de variáveis potenciais nos períodos que antecedem as crises em comparação com seus padrões normais de variação, definindo um limiar (*optimal threshold*), que, caso seja ultrapassado, sinaliza a aproximação de uma potencial crise. Além da pesquisa original, os trabalhos seminais que representam esse método foram conduzidos por Kaminsky & Reinhart (1999), Goldstein *et al.* (2000) e Edison (2003), além de uma série de autores que se sucederam utilizando a mesma linha de análise.

Em contrapartida, os modelos de regressão, cujas principais técnicas são *Probit* e *Logit*, utilizam ferramentas estatísticas para estimar a probabilidade de ocorrência de crise em função de variáveis explicativas. O modelo segue sendo aplicado com algumas variações a partir do trabalho citado anteriormente e os de autores como por exemplo: Eichengreen *et al.* (1995) e Demirgüç-Kunt & Detragiache (1998), dentre outros.

Mais recentemente, a partir do avanço da capacidade computacional e consequente possibilidade de se trabalhar um alto volume de dados com uma velocidade cada vez maior, observa-se um crescimento na utilização de técnicas de ML no desenvolvimento de EWSs para detecção de crises financeiras. Como consequência desse movimento em direção a uma abordagem de ciência de dados em complementação ou até oposição aos modelos puramente econométricos, alguns autores como Alessi & Detken (2018) e Holopainen & Sarlin (2017) vêm desenvolvendo estudos comparando as técnicas tradicionais a essa nova abordagem.

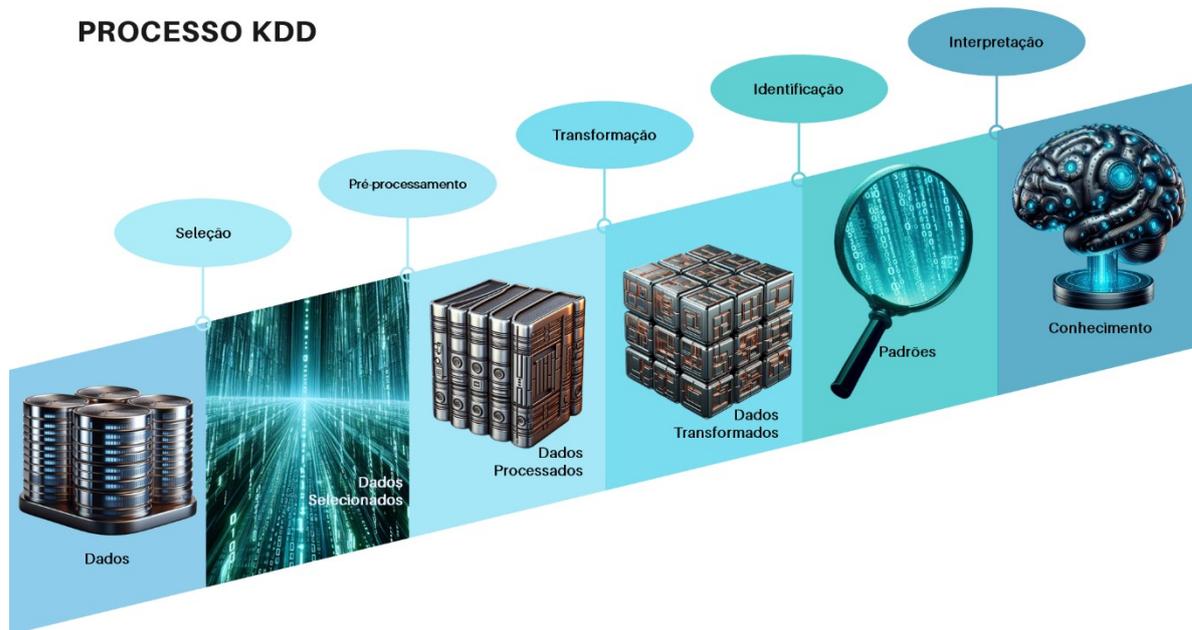
Liu *et al.* (2021) testam a performance de sete diferentes técnicas de ML em comparação ao modelo de regressão logística e concluem que as primeiras superam os modelos tradicionais em performance e acurácia. Os autores ressaltam ainda a utilidade da abordagem para os formuladores de políticas e sugerem o uso das técnicas de Inteligência Artificial associadas aos métodos tradicionais visando aprimorar a identificação dos riscos sistêmicos.

A OECD (2017) reconhece que a tecnologia, em especial, o emprego de algoritmos preditivos de ML, potencializa a implementação de EWSs inovadores em resposta ao nível crescente de complexidade e turbulência da atual conjuntura. Entretanto, apresenta a garantia dos freios e contrapesos como um dos principais desafios para sua utilização, que impacta diretamente os componentes da governança na tomada de decisão relacionada às políticas macroprudenciais, na medida em que cientistas de dados, que não detêm poder formal no processo podem influenciá-lo de forma oculta por meio do código implementado em ferramentas de Inteligência Artificial.

A questão principal não se refere a impedir que as máquinas assumam o controle dos humanos, mas sim, a governar o uso da análise de dados por humanos e a projetar mecanismos adequados que garantam a *accountability* e a transparência do processo decisório. O trabalho de Liu *et al.* (2021) vai ao encontro dessa preocupação quando apresenta os valores de *Shapley* como técnica para superar a incapacidade das ferramentas de ML em realizar análises de causa e efeito, o que, além de apontar os indicadores mais importantes, atenua o efeito “caixa-preta” dessas ferramentas.

### 3.2 TÉCNICAS DE MACHINE LEARNING

Como se pode observar, a extração de conhecimento em bases de dados por meio da aplicação de técnicas de ML tornou-se uma área significativa de pesquisa e desenvolvimento nos últimos anos. Hand *et al.* (2001) adicionam que o termo *Knowledge-Discovery in Databases* (KDD) originou-se no campo de pesquisa de Inteligência Artificial e envolve várias etapas (Figura 1), quais sejam: seleção, pré-processamento e transformação dos dados; identificação de padrões e relacionamentos; e interpretação.

Figura 1 - Fases *Knowledge-Discovery in Databases* (KDD)

Fonte: Desenvolvido pelo autor com base em Fayyad *et al.* (1996)

De acordo com Nazário *et al.* (2014), a extração do conhecimento é voltada para a obtenção de conhecimento a partir de agentes não-humanos, ademais, ML e KDD compartilham o mesmo objetivo de encontrar nos dados conhecimentos novos e úteis, e assim eles têm a maioria das técnicas e processos em comum. Isto posto, técnicas de ML têm demonstrado potencial em prover soluções para a previsão de crises financeiras por meio da identificação de padrões cuja detecção seria menos efetiva caso fosse realizada por seres humanos ou métodos estatísticos tradicionais.

Adicionalmente, sua capacidade de lidar com não-linearidades nos conjuntos de dados, bem como interações complexas em conjuntos de dados limitados representam vantagens significativas do uso de ML nesse contexto. Com efeito, diversas técnicas, a exemplo de árvores de decisão, *Random Forest* e redes neurais, dentre outras têm sido empregadas no desenvolvimento de modelos de EWSs para previsão de crises financeiras.

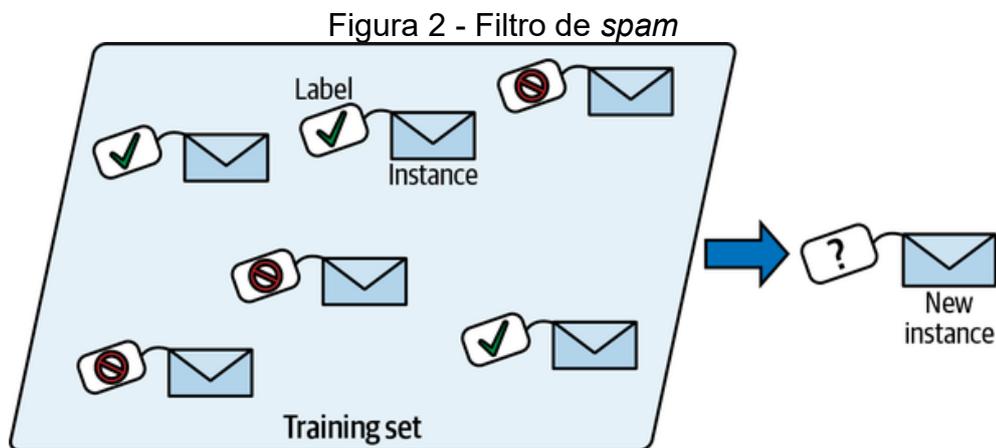
Esse é um campo em constante evolução e a cada dia surgem novas abordagens tanto como fruto do avanço exponencial da capacidade computacional quanto da crescente produção e disponibilização de dados. Nesse sentido, a presente seção não tem por fim esgotar o assunto *Machine Learning*, até porque seria impossível dado o fato de que já existe uma infinidade de métodos, técnicas e

ferramentas que podem ser usadas e combinadas para uma melhor solução dos problemas.

### 3.2.1 Tarefas

As questões mais comuns que podem ser tratadas por meio de técnicas de ML podem ser subdivididas em classificação, regressão, *clustering* e sistemas de recomendação. As primeiras, de modo simplificado, consistem em rotular amostras de dados conforme as categorias ou classes predefinidas com base em suas características ou atributos.

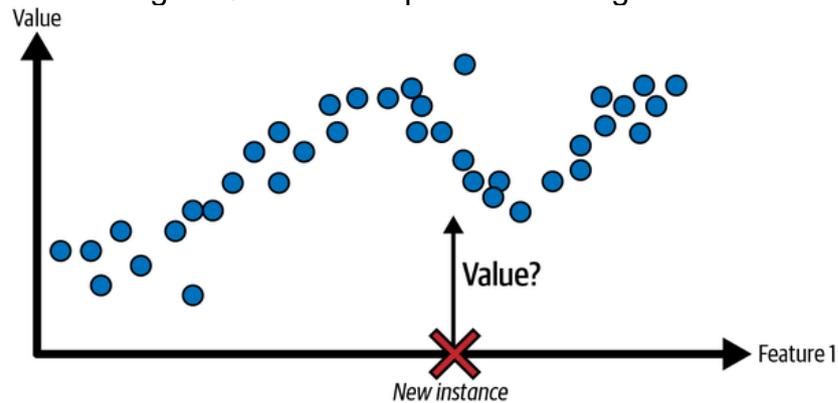
Conforme exemplifica Géron (2023), o filtro de *spam* é um caso típico de tarefa de classificação. A Figura 2 ilustra esse caso, em que o algoritmo é treinado com uma série de *e-mails* já categorizados como *spam* ou não de acordo com seu conteúdo e deve aprender a classificar as novas mensagens.



Fonte: Géron (2023)

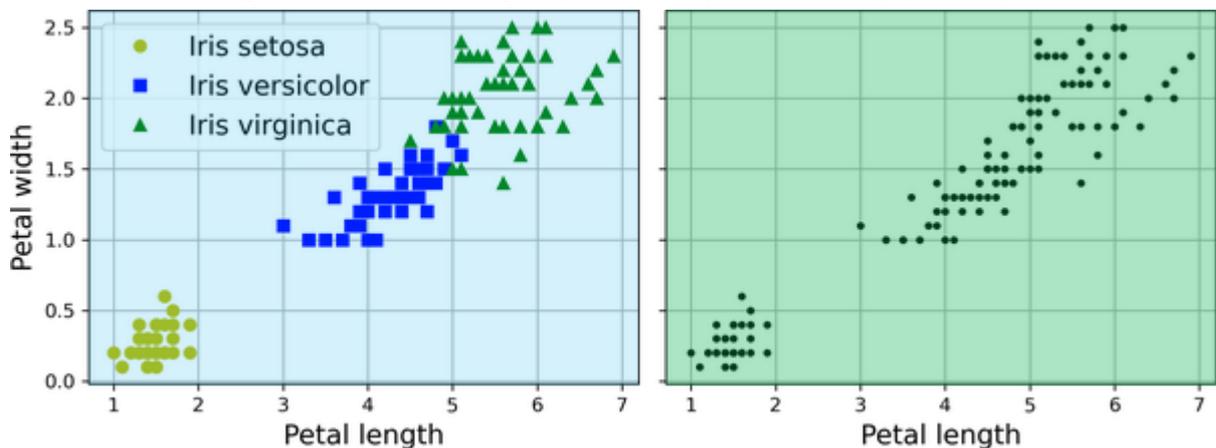
De acordo com Goodfellow *et al.* (2016), problemas de regressão envolvem a previsão de valores numéricos contínuos com base em variáveis de entrada ou atributos (*features*). Normalmente representam tarefas de modelagem preditiva, onde há a necessidade de estimar a correlação entre variáveis ou prever resultados futuros (*forecasting*), conforme ilustrado na figura a seguir.

Figura 3 - Previsão por meio de regressão



Fonte: Géron (2023)

*Clustering* agrupa os pontos de dados correlacionados com base em suas semelhanças ou distâncias geométricas. Géron (2023) ressalta que, como se pode observar na Figura 4, ao contrário da classificação, trata-se de uma tarefa de aprendizado não supervisionado em que o algoritmo não tem acesso a dados de treinamento rotulados, mas busca descobrir padrões ou estruturas subjacentes ao conjunto de dados.

Figura 4 - Classificação (esquerda) x *Clustering* (direita)

Fonte: Géron (2023)

Os sistemas de recomendação são amplamente utilizados em plataformas de comércio eletrônico, serviços de *streaming* e plataformas de mídia social para personalizar as experiências do usuário, por meio da sugestão de itens ou conteúdos relevantes. Segundo Bonaccorso (2017), esse tipo de sistema utiliza técnicas de ML

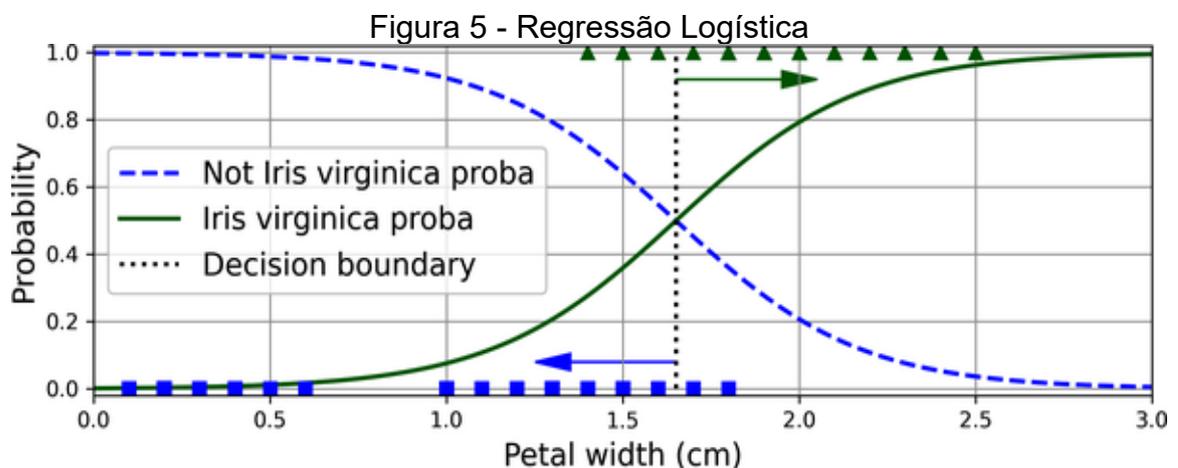
para analisar o comportamento do usuário para gerar recomendações precisas conforme suas preferências.

### 3.2.2 Abordagens

As técnicas de ML comumente são classificadas de acordo com três abordagens, quais sejam: aprendizado supervisionado, aprendizado não supervisionado e aprendizado por reforço (Géron, 2023). Entretanto, existem ainda outras categorias de interesse para o presente estudo, que surgem a partir da evolução das anteriores apoiada na crescente capacidade de processamento de dados, a saber: *deep learning* e *ensemble learning*.

Aprendizado supervisionado é usado extensivamente em tarefas de classificação e envolve o treinamento de um modelo com dados rotulados para fazer previsões ou classificar novas instâncias a partir de padrões pré-estabelecidos. Regressão logística, árvores de decisão e *Support Vector Machines* (SVM) são algoritmos populares nessa categoria (Géron, 2023).

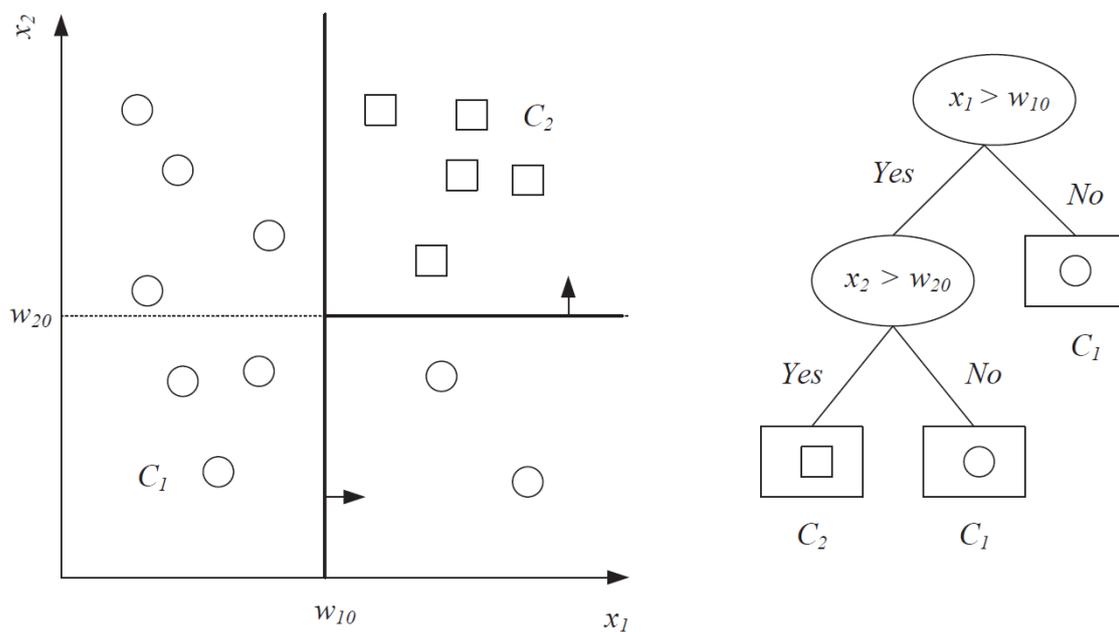
A técnica de regressão linear é usada para prever resultados contínuos por meio da construção de uma equação linear alimentada por variáveis de entrada e variáveis-alvo (Deisenroth *et al.*, 2020). Já a Regressão Logística (*Logit*) estende esse conceito para prever resultados binários usando funções logísticas e.g. estimar a probabilidade de uma espécie de flor a partir do tamanho de sua pétala, conforme demonstrado na Figura 5.



Fonte: Géron (2023)

Por seu turno, árvores de decisão são estruturas hierárquicas que dividem os dados com base em valores de características para tomar decisões ou classificações em cada ramo (Alpaydin, 2020). A adoção dessa técnica tem se difundido devido a sua interpretabilidade na medida em que provê uma maneira intuitiva de representar regras de decisão, conforme se pode observar na Figura 6, o que ameniza reputação de “caixa-preta” de grande parte das técnicas de ML.

Figura 6 - Interpretabilidade Árvores de Decisão



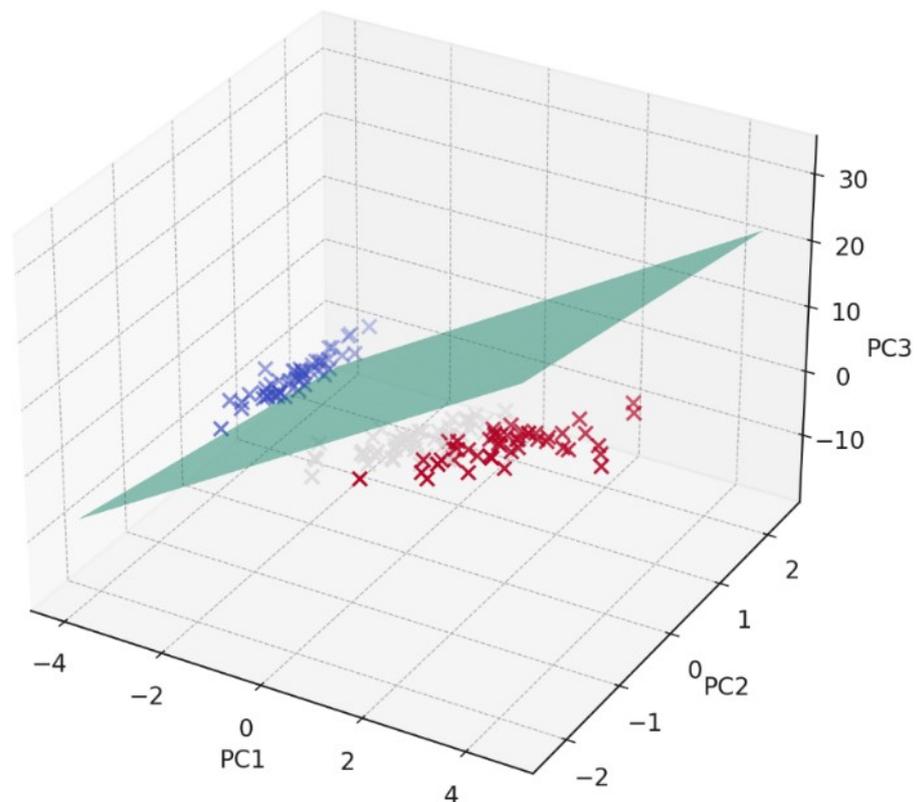
Fonte: Alpaydin (2020)

A técnica SVM, por outro lado, transforma espacialmente os dados de entrada para encontrar hiperplanos otimizados para tarefas de classificação. Objetivamente, SVM é uma técnica de aprendizado supervisionado que separa os dados no espaço em diferentes classes por meio da maximização da distância (margem) entre as regiões densas onde as amostras se encontram (Deisenroth *et al.*, 2020).

Métodos não supervisionados são empregados quando não há conhecimento prévio sobre rótulos de classe no conjunto de dados, o que os torna ferramentas importantes para análise exploratória e descoberta de padrões em tarefas de classificação. Algoritmos de agrupamento, como por exemplo *k-means*, dividem as instâncias similares em grupos com base em suas características utilizando métricas de distância (Deisenroth *et al.*, 2020).

A Figura 7 ilustra a utilização de SVM para transformar espacialmente dados multidimensionais e encontrar um hiperplano otimizado para classificá-los. Nesse exemplo, gerado por meio do sistema de IA generativa *ChatGPT* da *OpenAI*<sup>2</sup>, foi utilizada a base *Iris*<sup>3</sup>, um conjunto de dados clássico em exemplos de ML, e aplicada a técnica *Principal Component Analysis* (PCA) para reduzir a dimensionalidade dos dados para 3D.

Figura 7 - SVM e PCA



Fonte: Gerado pelo autor por meio do *ChatGPT*

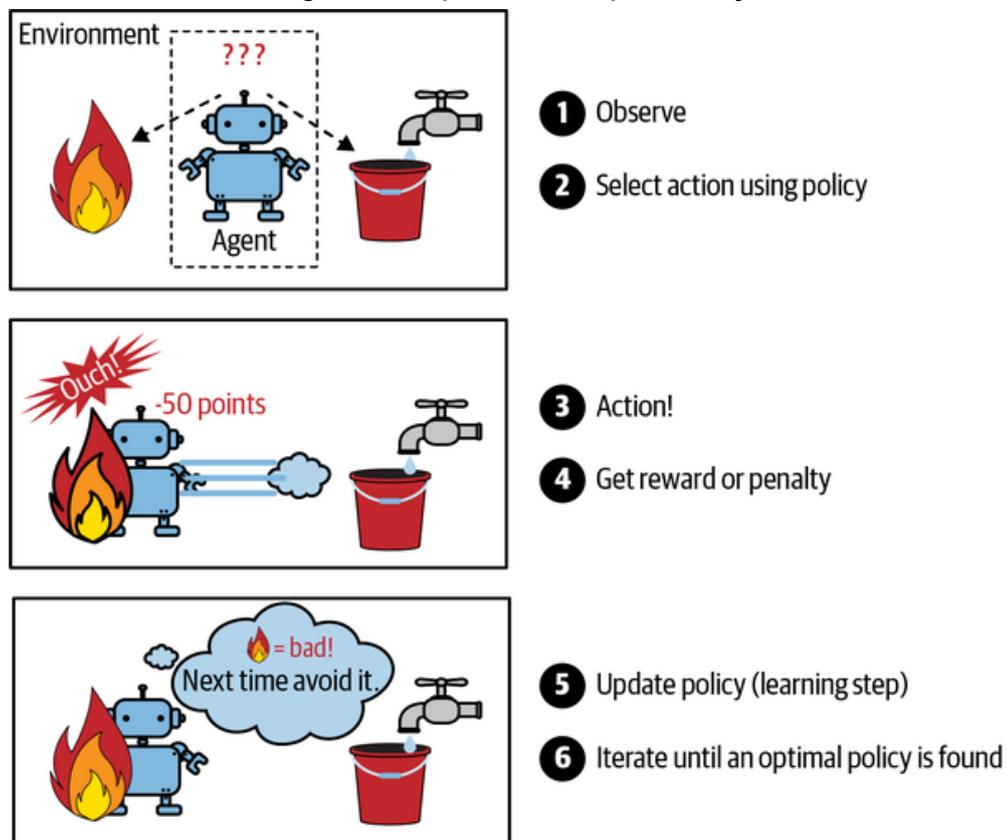
PCA, como outros métodos voltados à redução de dimensionalidade dos dados reduz o número de características enquanto preserva suas informações essenciais. A técnica transforma dados de alta dimensão em um espaço de menor dimensão, identificando eixos ortogonais que maximizam a variância (Jolliffe & Cadima, 2016).

<sup>2</sup> <https://chat.openai.com/>, acesso em 02 dez. 2023.

<sup>3</sup> <https://archive.ics.uci.edu/dataset/53/iris> acesso em 02 dez. 2023.

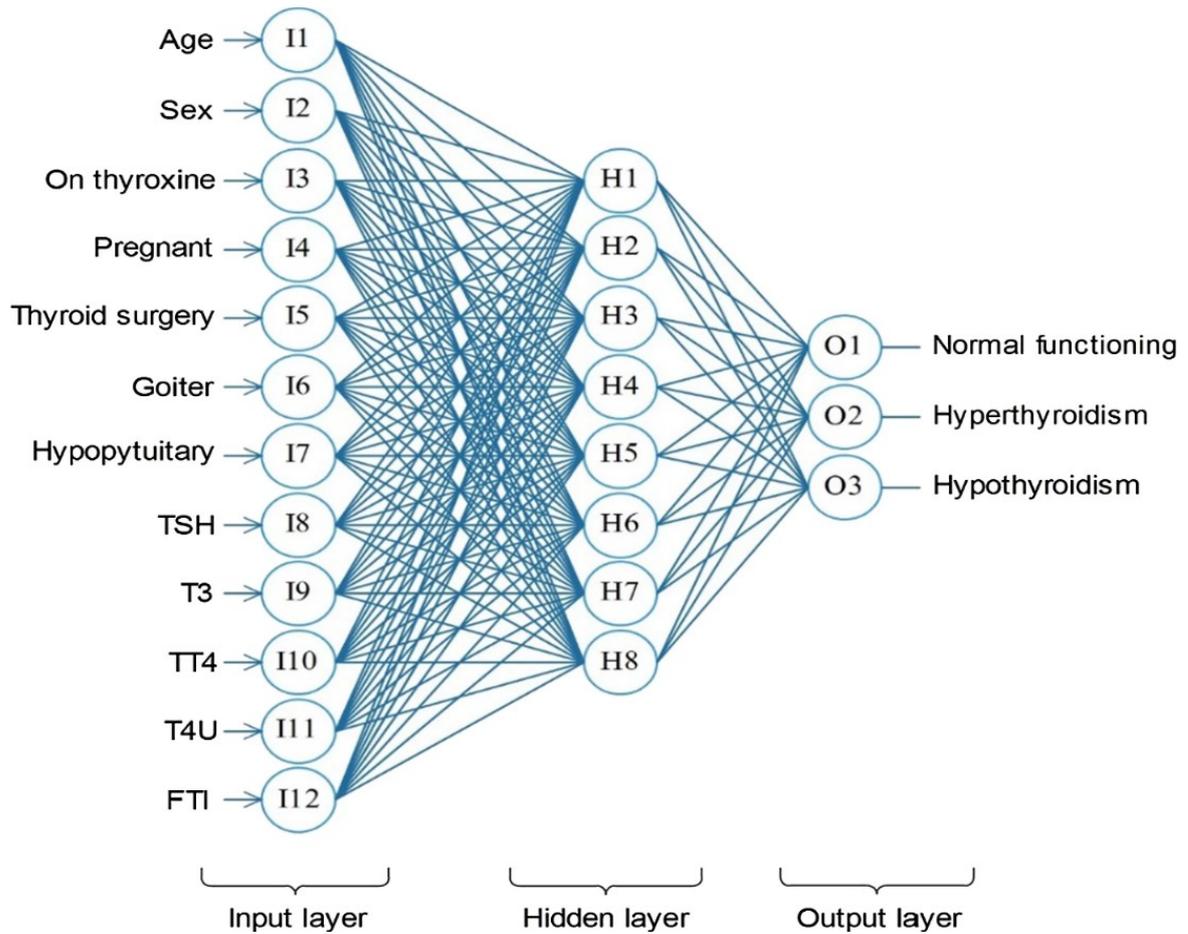
Conforme ilustrado na Figura 8, aprendizado por reforço utiliza uma metáfora do que seria a mesma abordagem aplicada fora do âmbito de ML, qual seja, um sistema de recompensas e punições para treinar um agente a tomar ações apropriadas com base em estados observados (Alpaydin, 2020). Apesar da aparente simplicidade, esse tema é extremamente amplo, entretanto, nos últimos anos, houve avanços ainda maiores, que permitem combinar modelos de *deep learning* com algoritmos simples para resolver problemas complexos.

Figura 8 - Aprendizado por reforço



Fonte: Géron (2023)

A propósito, *deep learning* utiliza redes neurais profundas (*Deep Neural Networks*) para capturar representações hierárquicas de dados, o que torna a técnica extremamente eficaz para tarefas complexas como reconhecimento de imagem e processamento de linguagem natural (Goodfellow *et al.*, 2016). A figura a seguir representa um *multilayer perceptron* – MLP, um tipo característico de rede neural, que, nesse caso, foi usado para a classificação de doenças da tireoide, alimentado por um conjunto de variáveis, cujas inter-relações são capturadas por camadas intermediárias denominadas *hidden layers*.

Figura 9 - *Multilayer Perceptron* – MLP

O conceito *deep learning* evoluiu para além da perspectiva neurocientífica e se refere a um princípio mais geral de aprender em múltiplos níveis, que se baseou no conhecimento do cérebro humano, da estatística e da matemática aplicada. Recentemente, sua popularidade e utilidade cresceram, tanto como fruto do avanço da capacidade computacional quanto da crescente produção e disponibilização de dados, mas também de técnicas para treinar redes mais profundas, o que representa uma oportunidade para levar a abordagem a novas fronteiras (Goodfellow *et al.*, 2016).

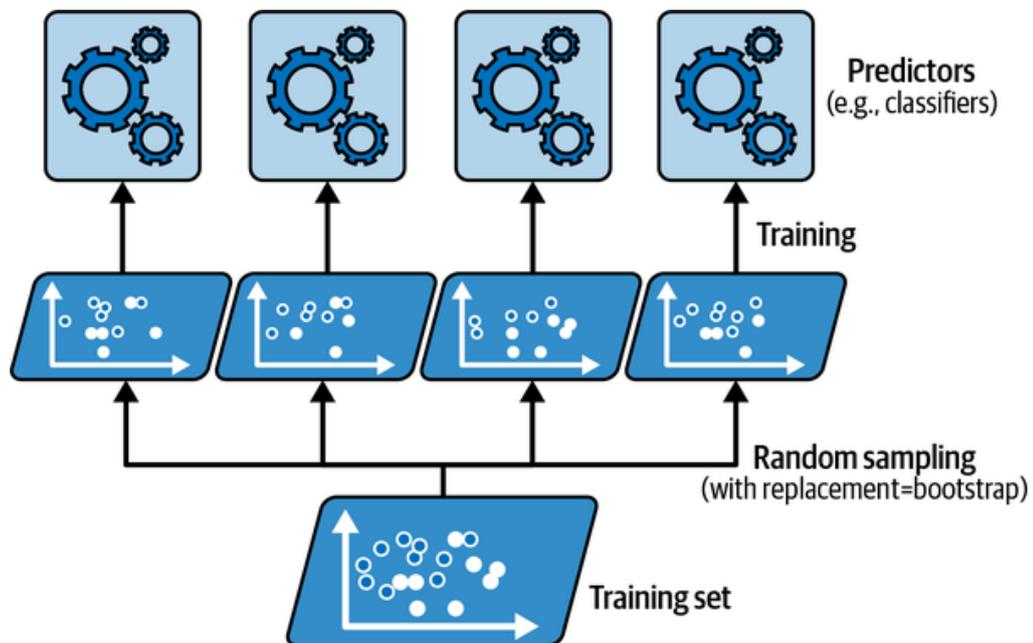
Um exemplo de *deep learning* que se popularizou recentemente, desde o lançamento de seu representante mais icônico, o *ChatGPT*, são os *Large Language Models* (LLMs). De acordo com Brown *et al.* (2020), esses modelos se baseiam em arquiteturas de redes neurais profundas, compostas por múltiplas camadas interconectadas que processam informações de maneira similar ao cérebro humano.

Essas redes são treinadas em vastos conjuntos de dados textuais, aprendendo a identificar padrões complexos e relações semânticas na linguagem. Segundo os autores, a capacidade dos LLMs de realizar tarefas de Processamento de Linguagem Natural (PLN) demonstra o poder do *Deep Learning* em extrair significado e conhecimento a partir de dados não estruturados, abrindo portas para aplicações inovadoras em diversas áreas.

Por fim, as abordagens de *ensemble learning* visam melhorar a precisão e robustez de modelos individuais combinando suas previsões. Pode-se segmentar essa categoria em três subcategorias principais, quais sejam: *Bagging*, *Boosting* e *Stacking*.

A primeira, que tem *Random Forest* como principal exemplo, é uma técnica popular que envolve o treinamento de várias cópias do mesmo algoritmo usando agregação *bootstrap* (*Bagging*) em diferentes subconjuntos aleatórios dos dados de treinamento, conforme ilustrado na Figura 10. As previsões de cada modelo são combinadas por votação (no caso de classificação) ou média (no caso de regressão) para produzir uma previsão final (Alpaydin, 2020).

Figura 10 - Agregação *bootstrap* (*Bagging*)



Fonte: Géron (2023)

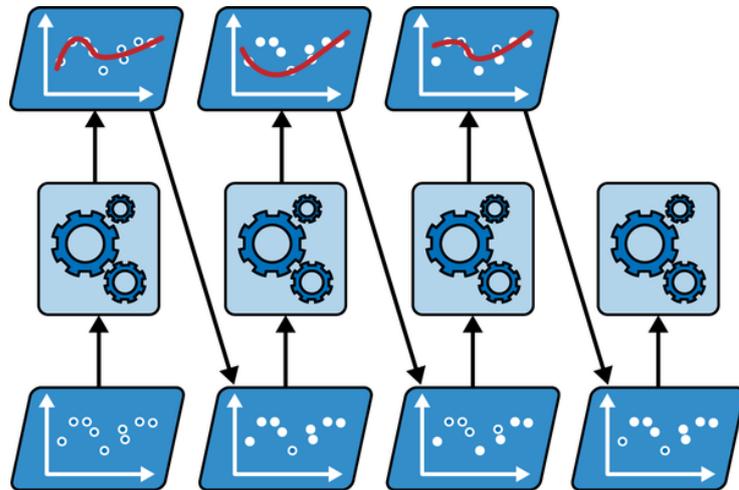
*Random Forest* é uma técnica que combina várias instâncias de árvores de decisão para reduzir o *overfitting* e melhorar a precisão, conseqüentemente aumentar o desempenho e a estabilidade do modelo final (Breiman, 2001). Esses algoritmos usam entropia para determinar a importância das *features* durante a construção da árvore, permitindo que eles identifiquem aquelas mais importantes para tarefas de previsão ou classificação.

O conceito de entropia surgiu na termodinâmica como uma medida de desordem molecular e se expandiu para áreas como a teoria da informação, em que especifica o número mínimo de *bits* necessários para codificar uma mensagem. Em ML, é usada como medida de impureza, indicando que um conjunto é puro quando possui entropia zero ou, em outros termos, contém instâncias de apenas uma classe (Géron, 2023).

*Overfitting* ocorre quando o modelo está tão precisamente ajustado aos dados de treinamento que não permite generalização, ou seja, a hipótese escolhida falha para novos dados (Deisenroth *et al.*, 2020). Nessa mesma linha, devido às características dos problemas tratados nesta dissertação, outra questão que deverá ser tratada é o desbalanceamento da base de dados.

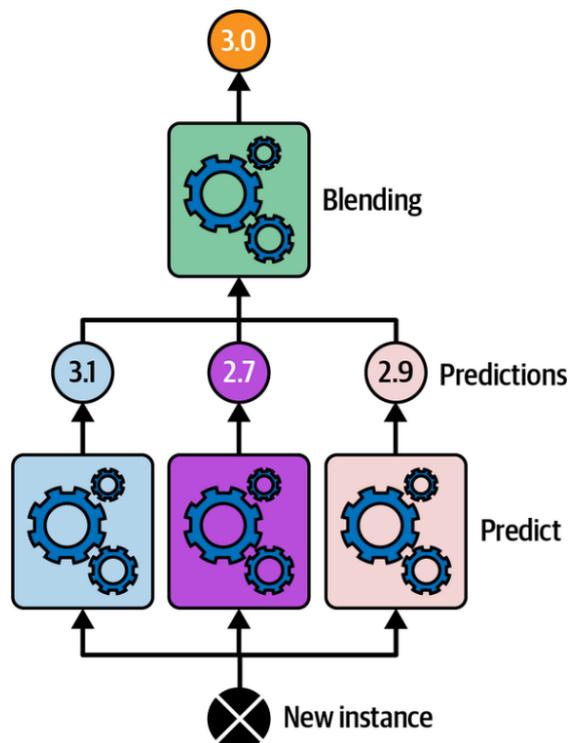
Os dados estão balanceados quando a quantidade de registros de cada classe é a mesma ou apresenta uma pequena diferença percentual, dessa forma, todas as classes estão igualmente representadas (Kuhn & Johnson, 2018). Esse problema é comum em tarefas de classificação, como é o caso desta dissertação, na medida em que os eventos de crises são raros em relação aos momentos em que não há crise.

De volta à segmentação de *ensemble learning*, *Boosting* é uma abordagem que se concentra em treinar iterativamente classificadores fracos sequencialmente e ajustar os pesos das instâncias com base em erros de classificação a exemplo do algoritmo *AdaBoost* proposto por Freund & Schapire (1996). Nessa técnica, ilustrada na Figura 11 cada novo modelo é treinado para corrigir os erros do modelo anterior, dando mais importância aos exemplos que foram classificados incorretamente e gerando previsões finais por meio de uma combinação ponderada das previsões de todos os modelos individuais.

Figura 11 - *AdaBoost*

Fonte: Géron (2023)

Finalmente, *Stacking (stacked generalization)* é uma estratégia que compreende o treinamento de múltiplos modelos-base e, em seguida, um modelo final (*blender* ou *meta learner*) é treinado para fazer previsões usando as saídas dos modelos de entrada (Géron, 2023). A Figura 12 mostra um conjunto de preditores realizando uma tarefa de regressão em que cada um prevê um valor diferente e em seguida, o meta-modelo recebe essas previsões como entradas e faz a previsão final.

Figura 12 - *Stacked Generalization*

Fonte: Géron (2023)

### 3.2.3 Métricas de avaliação

Para avaliar o desempenho dos modelos de ML, são normalmente utilizadas as métricas AUC (*Area Under ROC Curve*), acurácia, precisão, *recall* e *F1-Score*. Ademais, também é utilizada a matriz de confusão para detalhar a qualidade do modelo.

AUC é a área sob a Curva Característica de Operação do Receptor, do inglês, *Receiver Operating Characteristic Curve*, ou, simplesmente, curva ROC. Esta, por sua vez, é uma representação gráfica que ilustra o desempenho de um sistema classificador binário por meio do equilíbrio entre a taxa de verdadeiros positivos (sensibilidade) e a taxa de falsos positivos (especificidade) em vários limiares de classificação (Bonaccorso, 2017).

A área sob essa curva fornece uma medida agregada da precisão geral do modelo. Sua importância reside na capacidade de quantificar o quão bem um classificador se comporta em diferentes níveis de sensibilidade e especificidade simultaneamente.

Acurácia da classificação representa a proporção de previsões corretas feitas por um classificador em relação ao total de previsões feitas em dados de teste (Bonaccorso, 2017). Essa é talvez uma das medidas de desempenho mais simples e diretas para classificadores, embora apresente limitações como medida única para avaliar o desempenho do modelo, por exemplo, ao lidar com conjuntos de dados desequilibrados nos quais uma classe domina sobre as outras.

Precisão, por sua vez, é a proporção de verdadeiros positivos (instâncias positivas corretamente previstas) em relação a todas as instâncias positivas previstas (Bonaccorso, 2017). Fornece, portanto, informações sobre o quão confiáveis ou exatas são as previsões do classificador para instâncias positivas, o que é útil em casos em que é importante minimizar falsos positivos.

*Recall*, por seu turno, mede a sensibilidade do modelo por meio da proporção de instâncias positivas corretamente previstas em relação a todas as instâncias positivas reais no conjunto de dados (Bonaccorso, 2017). A importância do *recall* se dá por sua capacidade de capturar o quão bem um classificador identifica todos os casos positivos relevantes em um conjunto de dados.

*F1-score* é a média harmônica ponderada entre precisão e *recall* (Bonaccorso, 2017). O que o torna particularmente útil ao lidar com conjuntos de dados desequilibrados, nos quais é crucial capturar verdadeiros positivos enquanto minimiza falsos negativos.

Por fim, a matriz de confusão exibe, conforme quadro a seguir, a distribuição dos registros em termos de suas classes reais e de suas classes previstas (Bonaccorso, 2017). Isso indica a qualidade do modelo atual por meio das taxas de verdadeiros e falsos positivos versus verdadeiros e falsos negativos.

Quadro 2 - Matriz de confusão

	Classe Positiva (Real)	Classe Negativa (Real)
Classe Positiva (Previsto)	<p><b>TP</b></p> <p>(Instâncias Positivas corretamente classificadas)</p>	<p><b>FP</b></p> <p>(Instâncias Negativas classificadas como positivas)</p> <p>Erro tipo I</p>
Classe Negativa (Previsto)	<p><b>FN</b></p> <p>(Instâncias Positivas classificadas como negativas)</p> <p>Erro tipo II</p>	<p><b>TN</b></p> <p>(Instâncias Negativas corretamente classificadas.)</p>

Fonte: Elaborado pelo autor

Essa representação da distribuição das previsões do modelo em relação às classes reais permite identificar visualmente as taxas de acertos e de erros do modelo. É possível observar na matriz os dois tipos tradicionais de erros estatísticos que, segundo Neyman & Pearson (1933), raramente podem ser eliminados, a saber: rejeitar uma hipótese verdadeira e aceitar uma hipótese falsa.

Em muitos casos, maximizar a precisão, ou seja, a capacidade de o modelo prever corretamente a classe positiva, pode levar a uma diminuição da sensibilidade, que reflete a habilidade do modelo em identificar as instâncias relevantes da classe positiva. A análise dessas taxas de erros traz à tona o *trade-off* entre precisão e sensibilidade, de acordo com Géron (2023), um importante e inevitável aspecto a ser considerado na avaliação de modelos de classificação, o que suscita uma análise cuidadosa do contexto do problema em tela e dos objetivos do modelo.

## 4 ESTADO DO CONHECIMENTO

Este capítulo faz parte da fase de Identificação do problema e motivação, quanto abordada na metodologia de pesquisa, tendo em vista, respectivamente o objetivo de mapear o uso de técnicas de ML em EWSs para crises financeiras no âmbito do sistema financeiro global. A primeira revisão de literatura realizada no âmbito da presente pesquisa mapeou a produção científica relativa a Sistemas de Alerta Precoce para Crises Financeiras sistêmicas e a segunda, abordou o conhecimento empírico relacionado a EWSs que utilizam técnicas de ML.

### 4.1 EWSs PARA CRISES FINANCEIRAS

Chambers *et al.* (2011) destacaram que as revisões de literatura devem utilizar recursos que se adaptem e apresentem os resultados em formatos mais diretamente adaptados às necessidades dos formuladores de políticas. Adicionalmente, uma das razões apontadas por Arksey & O'Malley (2005) para conduzir uma revisão de escopo é resumir e divulgar os resultados de pesquisa para formuladores de políticas, particularmente, em um corpo de evidências novo, heterogêneo ou complexo.

Dito isso, o *Canadian Institutes of Health Research*, define revisões de escopo como projetos exploratórios que mapeiam sistematicamente a literatura disponível sobre um determinado tema, identificando conceitos-chave, teorias, fontes de evidência e lacunas na pesquisa (Grimshaw, 2010). Por outro lado, Arksey & O'Malley (2005) identificam quatro possíveis razões para a realização de uma revisão de escopo, quais sejam: examinar a extensão, o alcance e a natureza da atividade de pesquisa, em um determinado tema; identificar a conveniência de se realizar uma revisão sistemática completa; resumir e divulgar os resultados de um conjunto de evidências de pesquisa; e identificar lacunas de pesquisa na literatura para auxiliar no planejamento e desenvolvimento de pesquisas futuras.

Os autores sugerem ainda que há duas maneiras diferentes de pensar o papel de uma revisão de escopo: as duas primeiras razões conduzem a um estudo concebido como parte de um processo mais extenso, que culminaria com uma revisão sistemática. Em outra direção, as duas seguintes apontam para um estudo de escopo como um método completo, voltado à publicação e disseminação de resultados de pesquisa em um campo específico de investigação.

Com relação à abordagem utilizada para a revisão de escopo, o incremento no uso motivou o aprimoramento da qualidade metodológica e de comunicação desse tipo de pesquisa. Com esse intuito, foi proposto o protocolo PRISMA-SCR, uma extensão do PRISMA (*Preferred Reporting Items for Systematic reviews and Meta-Analyses*) a partir das melhores práticas relacionadas à ética e transparência em pesquisas científicas na área de saúde e validado por um painel de especialistas, conforme relatam Tricco *et al.* (2018).

Conforme se pode depreender, a revisão de escopo se apresenta alinhada aos objetivos do presente trabalho ao representar uma metodologia dotada de rigor científico e adequada para resumir e divulgar evidências de determinado campo de pesquisa para formuladores de políticas em geral e macroprudenciais em particular. Ademais, identificou-se como estratégia para realizar a pesquisa o protocolo PRISMA-SCR<sup>4</sup>, desenvolvido com base no PRISMA (*Preferred Reporting Items for Systematic reviews and Meta-Analyses*) publicado pelo *Joanna Briggs Institute*<sup>5</sup>, cujo resumo aplicado ao contexto dessa revisão se encontra no Apêndice A.

#### 4.1.1 Resultados

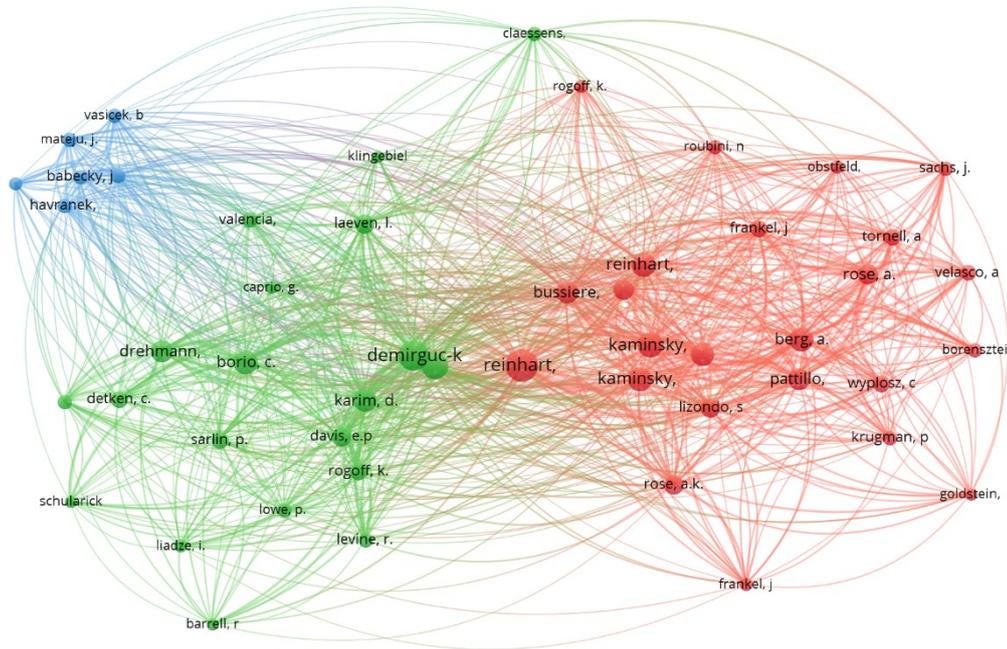
As referências e suas interconexões representados na Figura 13 trazem como nós centrais os principais autores que representam os trabalhos seminais no tema da presente pesquisa. Esse fato aliado ao mapa representativo das principais palavras-chave utilizadas nos artigos (Figura 14) que constam da amostra pesquisada podem ser interpretados como um sinal da aderência da amostra aos objetivos deste trabalho.

---

<sup>4</sup> Disponível em <http://www.prisma-statement.org/Extensions/ScopingReviews>, acesso em: 03 fev 2022

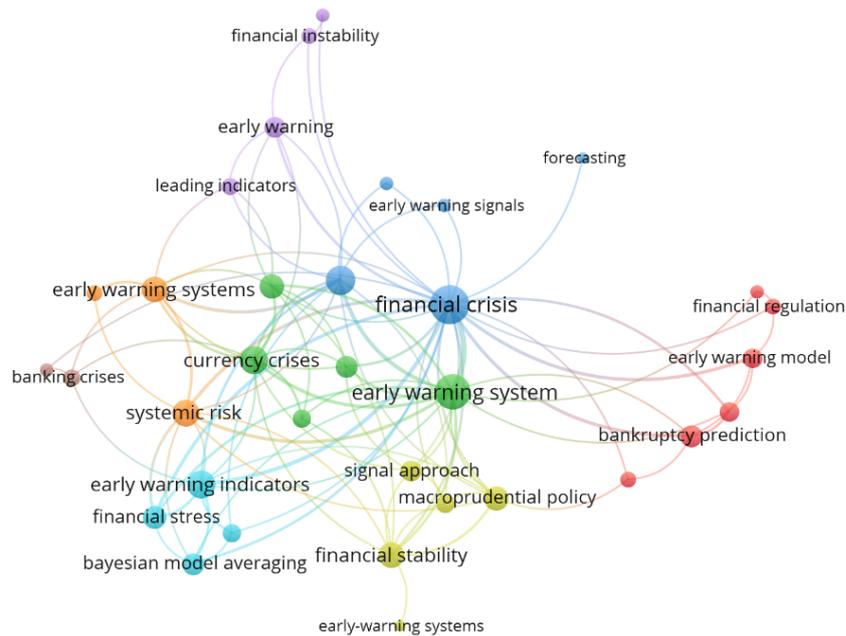
<sup>5</sup> O Instituto Joanna Briggs (JBI) é uma organização internacional de pesquisa com sede na Faculdade de Saúde e Ciências Médicas da Universidade de Adelaide na Austrália. A JBI desenvolve e fornece informações, *software*, educação e treinamento baseados em evidências, para melhorar a prática e os resultados na área de saúde. (<https://jbi.global/>)

Figura 13 - Mapa dos autores e suas interconexões



Fonte: Desenvolvido pelo autor por meio do *software* VOSviewer

Figura 14 - Mapa das principais palavras-chave e suas interconexões



Fonte: Desenvolvido pelo autor por meio do *software* VOSviewer

Como resultado do processo de leitura e análise das fontes de evidência, os artigos foram padronizados e sintetizados para responder à questão e aos objetivos

da pesquisa no Quadro 3 por meio dos seguintes campos: autores, ano, método, indicadores (relevantes) e amostra (período e países).

Quadro 3 - Síntese dos dados

(continua)

Autor	Ano	Método	Indicadores	Amostra	
				Período	Países
Aikman <i>et al.</i>	2017	Outros		1990 2016	Estados Unidos
Apoteker & Barthélémy	2005	<i>Machine Learning</i>		1980 2002	Economias Emergentes
Barişik & Tay	2010	Modelos de Regressão	Conta corrente Crédito Reservas Taxa de câmbio real	1994 2006	Economias Emergentes
Bunda & Ca'Zorzi	2010	Modelos de Regressão	Composição da dívida Conta corrente Economia real PIB	1980 2008	Sem Segmentação
Bussiere & Fratzscher	2006	Modelos de Regressão	Composição da dívida Conta corrente Contágio PIB Taxa de câmbio real	1993 2001	Economias Emergentes
Christensen & Li	2014	Abordagem por Sinais	PIB Taxa de juros real Inflação Taxa de câmbio real Conta corrente Crédito Composição da dívida Base monetária Retorno sobre o patrimônio Taxa básica de juros Contágio	1981 2010	13 Países OECD
Lo Duca & Peltonen	2013	Modelos de Regressão		1990 2009	10 Países Desenvolvidos e 18 Economias Emergentes
Edison	2003	Abordagem por Sinais	Base monetária Composição da dívida Reservas Retorno s/ patrimônio Taxa de câmbio real	1970 1995	28 Países, tanto Países Desenvolvidos quanto Economias Emergentes, 3 Grupos Regionais: América Latina, Ásia e outros.
Fioramanti	2008	<i>Machine Learning</i>		1980 2004	46 Economias Emergentes
Frankel & Saravelos	2012	Modelos de Regressão	Reservas Taxa de câmbio real	2007	A depender da Variável Analisada
Galán & Mencía	2021	Outros	Crédito	1970 2016	Países Europeus (França, Alemanha, Itália, Holanda, Espanha)

Quadro 3 - Síntese dos dados

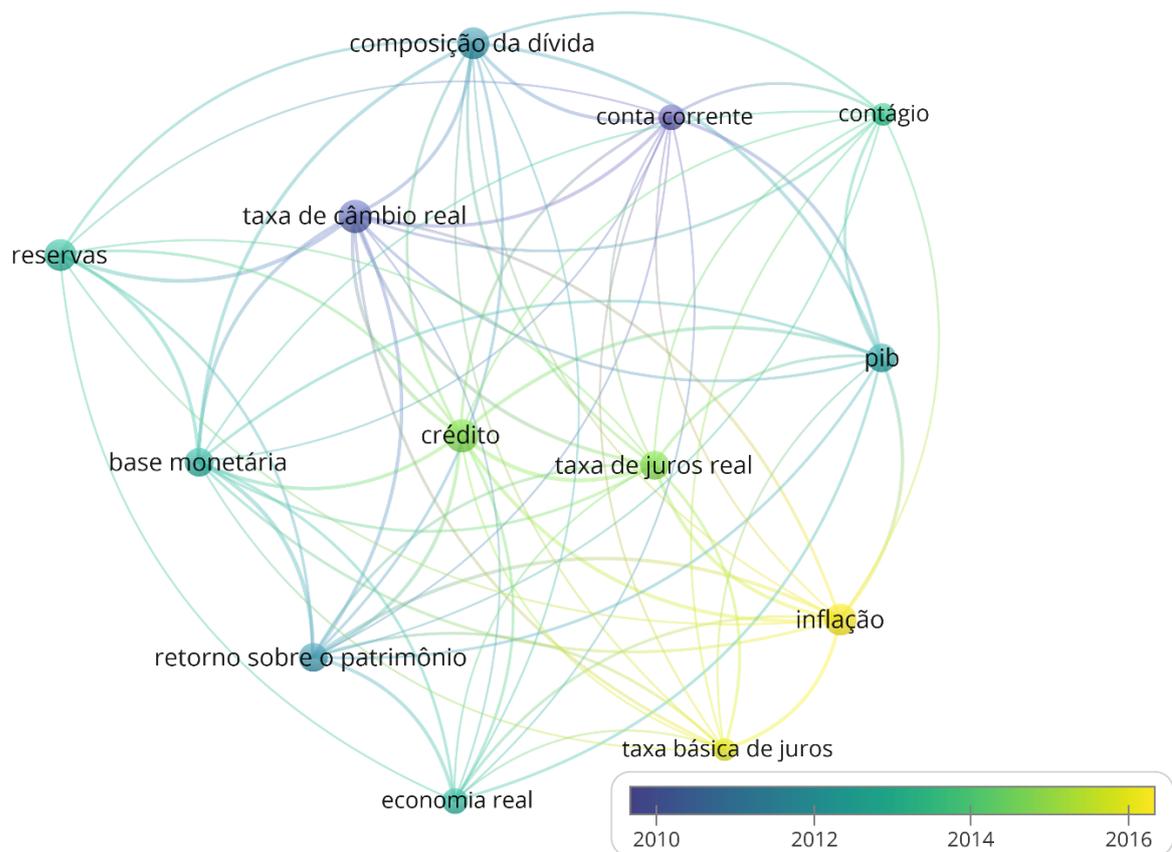
(conclusão)

Autor	Ano	Método	Indicadores	Amostra	
				Período	Países
Guru	2016	Modelos de Regressão	Dívida externa Economia real Inflação Retorno s/ patrimônio Taxa básica de juros	2001 2012	Índia
Jemović & Marinković	2021	Modelos de Regressão	Base monetária Composição da dívida Legal Reservas	1977 2013	50 Países Variados
Joy <i>et al.</i>	2017	<i>Machine Learning</i>	Inflação Taxa básica de juros Taxa de câmbio real Taxa de juros real	1970 2010	36 Países Desenvolvidos
Kamin <i>et al.</i>	2007	Modelos de Regressão		1981 1999	26 Economias Emergentes
Liu <i>et al.</i>	2021	<i>Machine Learning</i>	Inflação Reservas	1970 2017	119 Países
Manasse <i>et al.</i>	2016	<i>Machine Learning</i>	Composição da dívida Crédito Fluxo de capital Taxa de juros real	1980 2010	85 Economias Emergentes
Nik et al	2016	<i>Machine Learning</i>	Crédito Inflação Legal PIB Taxa de juros real	1992 2011	BRICS
Samitas <i>et al.</i>	2020	<i>Machine Learning</i>	Contágio	2004 2016	33 Economias Europa, América do Norte e do Sul, África e Ásia.
Shi & Gao	2010	Abordagem por Sinais	Base monetária Crédito Economia real Exportação / importação Reservas Retorno s/ patrimônio Taxa de câmbio real Taxa de juros real Termos de Troca	2006 2009	Chile, Zona do Euro, Islândia, Índia, Japão, Coreia, Malásia, México, Paquistão, Rússia, Grã-Bretanha, Estados Unidos, Vietnã, Argentina, Austrália, Brasil, China, Indonésia, Noruega, Filipinas, África do Sul e Tailândia.
Wang <i>et al.</i>	2021	<i>Machine Learning</i>		1981 2017	95 Economias
Zigraiova & Jakubik	2015	Modelos de Regressão	Base monetária Crédito Economia real Inflação PIB Retorno s/ patrimônio	2005 2013	14 Países

Fonte: Elaborado pelo autor

A partir do entendimento, análise e abstração dos indicadores utilizados na construção de cada EWS proposto pelos autores e relacionando-os aos trabalhos de Frankel & Saravadelos (2012) e Kaminsky (1998), com o auxílio do *software* VOSviewer, foi possível construir o seguinte mapa (Figura 15), que apresenta o respectivo dado com seus relacionamentos e uma visão temporal:

Figura 15 - Visão temporal dos indicadores



Fonte: Desenvolvido pelo autor por meio do *software* VOSviewer

Por meio do mapa, é possível observar que, embora nem todos sejam os mais utilizados ainda, possivelmente em virtude de seu uso mais recente, os indicadores de taxa de juros real, crédito, inflação e taxa básica de juros apresentam uma tendência crescente de importância. Já no gráfico de quadrantes a seguir, desenvolvido com base no cruzamento entre os métodos utilizados e os indicadores apontados como relevantes em cada estudo, é possível observar que os modelos de regressão e a abordagem de sinais apresentam uma maior variedade na utilização de indicadores, além disso, também é evidente a irrelevância do uso de outros métodos em relação aos três mais estabelecidos.

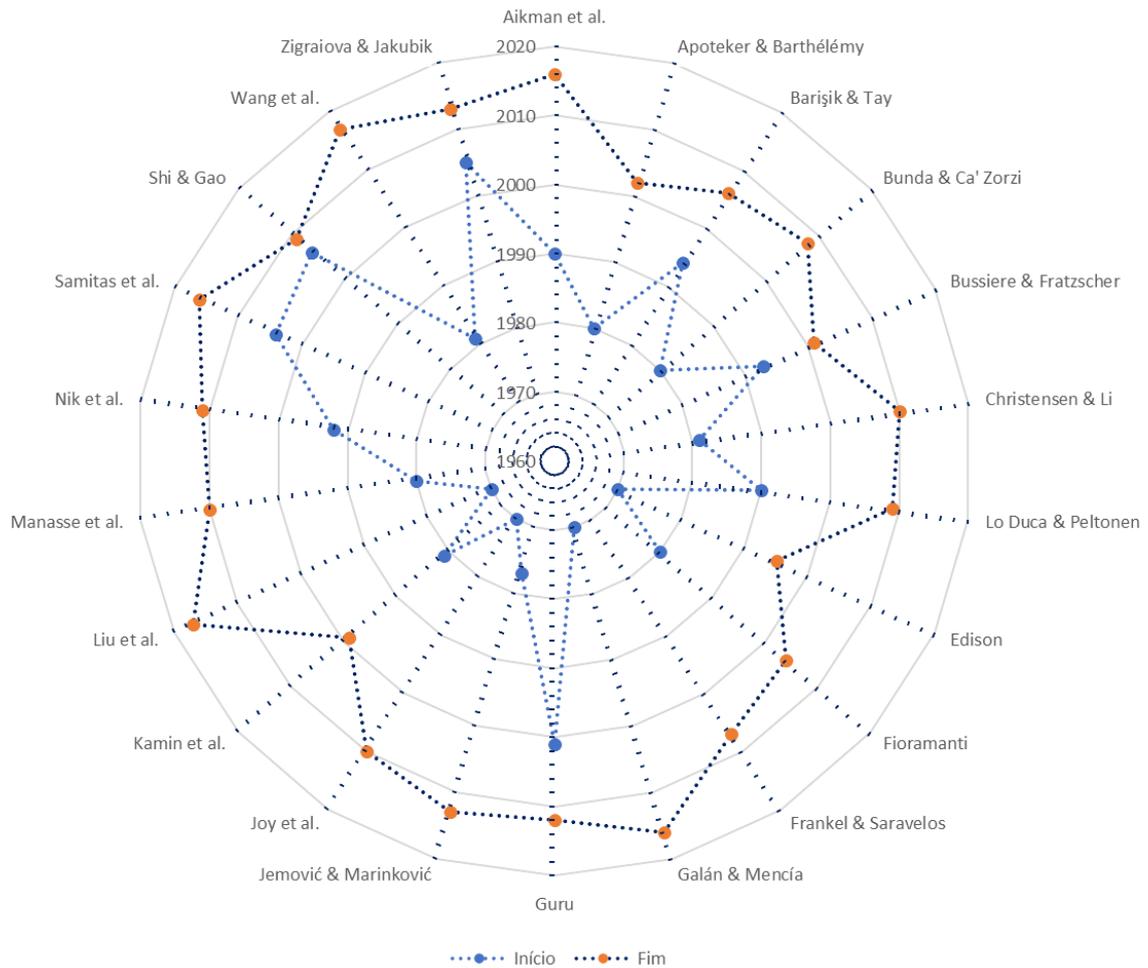
Gráfico 1 - Métodos X indicadores



Fonte: Elaborado pelo autor

Por fim, vale destacar a característica temporal das bases de dados utilizadas em cada estudo para desenvolvimento e análise dos EWSs. Para isso, conforme amplamente preconizado na literatura relacionada a revisões sistemáticas, a seguir é apresentada de forma gráfica para melhor visualização, a distribuição das amostras ao longo dos anos.

Gráfico 2 - Distribuição das amostras ao longo dos anos



#### 4.1.2 Discussão

Na revisão de escopo, conforme fluxo demonstrado no Apêndice B, foram avaliados 22 estudos primários, publicados entre 2003 e 2021, que abordam o desenvolvimento de Sistemas de Alerta Precoce para crises financeiras sistêmicas. A pesquisa encontrou uma área ainda em desenvolvimento, cujos primeiros artigos foram publicados no final da década de 1990 e que está ganhando importância na medida em que os episódios sistêmicos se avolumam em quantidade e extensão de danos.

#### 4.1.2.1 Sumário das evidências

A pesquisa indicou que as amostras sobre as quais foram realizados os estudos empíricos diferem bastante em termos de desenvolvimento econômico ou localização geográfica, por exemplo, bem como quanto ao período de estudo, que sinaliza que as conclusões dificilmente podem ser generalizáveis para outros casos. Todavia, foi possível responder à questão de pesquisa por meio dos interessantes achados e *gaps* de pesquisa encontrados, que se encontram relatados a seguir de acordo com os objetivos específicos estabelecidos.

##### 4.1.2.1.1 Padrões, índices e indicadores

Na maioria dos estudos analisados, os autores identificam um conjunto de variáveis com potencial para sinalizar a ocorrência ou aproximação de uma crise financeira, aplicam o método e identificam os “*leading indicators*”, ou seja, aqueles indicadores que passam a fazer parte do EWS proposto. Também foi possível observar que alguns autores não apresentaram um conjunto final de indicadores ou não avaliam as variáveis de entrada porque não foi possível, em virtude do método utilizado, ou mesmo porque não fazia parte do objetivo do estudo.

As variáveis, índices e indicadores possuem níveis de agregação muito heterogêneos, assim, foi um desafio encontrar categorias que homogeneizassem a amostra para que fosse possível sintetizar e traduzir as evidências de forma clara. Entretanto, a partir do entendimento do contexto do indicador e muitas vezes, do próprio cálculo, foi possível relacioná-los a pesquisas já sedimentadas e amplamente reconhecidas, nomeadamente, a de Frankel & Saravadelos (2012), que sistematiza e ranqueia indicadores encontrados em estudos anteriores a 2008.

Dito isso, comparativamente à mencionada pesquisa, crédito, taxa de câmbio real, reservas, PIB e base monetária continuam sobressaindo como indicadores relevantes, independentemente do método utilizado, com destaque para os dois primeiros, que se apresentaram com maior possibilidade de apontar crises nos estudos avaliados. Entretanto, indicadores de conta corrente e exportação/importação não apresentaram muita prevalência na amostra.

Por outro lado, composição da dívida, inflação, taxa real de juros e retorno sobre o patrimônio apresentaram uma maior importância em relação à pesquisa de Frankel & Saravadelos (2012). Cabe ressaltar que os indicadores relacionados a taxa básica de juros e contágio começam a ganhar destaque em estudos mais recentes, designadamente, nos trabalhos de Guru (2016) e Joy *et al.* (2017), no caso do primeiro, e Samitas *et al.* (2020), do último.

#### 4.1.2.1.2 Métodos, técnicas e ferramentas

É possível destacar algumas diferenças latentes entre os métodos em relação aos indicadores, entretanto, a aplicação das técnicas tradicionais é bastante homogênea entre os autores. Na abordagem por sinais, a estratégia para construção do sistema de alerta é definir os limiares que, se ultrapassados deflagram um sinal de alerta, já nos modelos de regressão, a relevância das variáveis e de suas interrelações é analisada estatisticamente para se chegar a um conjunto final de indicadores.

Por seu turno, os sistemas que utilizam ML não apresentam um padrão facilmente perceptível de identificação de variáveis e definição de indicadores, tendo em vista as diferentes possibilidades de técnicas utilizadas. Joy *et al.* (2017), por exemplo, utilizam *Random Forest*, para detectar variáveis-chave e determinar os pontos críticos de inflexão, já Wang *et al.* (2021), recorrem à mesma técnica para simular um processo de votação de especialistas, contudo, não apresentam um conjunto de “*leading indicators*” e acrescentam que a precisão do resultado é diretamente proporcional à quantidade de variáveis fornecidas.

Samitas *et al.* (2020) testam uma série de ferramentas para predição do risco de contágio e apontam que *Support Vector Machines* (SVM) é a mais acurada para o caso em estudo. Liu *et al.* (2021) trazem outro olhar na medida em que testam a performance de sete diferentes técnicas de ML em comparação ao modelo de regressão logística e concluem que as primeiras superam os modelos tradicionais em performance e acurácia.

Os autores empregam ainda o valor de *Shapley* como técnica para superar a incapacidade das técnicas de ML para realizar análises de causa e efeito, o que, além de apontar os indicadores mais importantes, atenua o efeito “caixa-preta” dessas ferramentas. Por fim, ressaltam a utilidade da abordagem para os formuladores de

políticas e sugerem o uso das técnicas de Inteligência Artificial associadas aos métodos tradicionais visando aprimorar a identificação dos riscos sistêmicos.

#### 4.1.2.1.3 Tendências

Como se pode depreender, os estudos sobre o uso das técnicas de ML apresentam infinitas possibilidades e esse ainda é um campo em pleno desenvolvimento. Há que se atentar, contudo, para a maior limitação a sua adoção, que se refere à reputação de “caixa-preta” de grande parte das técnicas utilizadas e ainda, à estrutura complexa, características que trazem resistência a seu uso por parte dos tomadores de decisão e formuladores de políticas públicas.

Quanto aos indicadores, na construção de novos EWSs, há uma propensão a explorar o potencial de novos indicadores, como os ligados a contágio e às taxas dos títulos públicos, por sua vez, aqueles já testados e estabelecidos também mantêm sua importância. Finalmente, talvez haja uma tendência em aproveitar a capacidade computacional e a das ferramentas de Inteligência Artificial para trabalhar com um maior volume de dados e indicadores e assim, aumentar também a capacidade de predição dos Sistemas de Alerta Precoce.

#### 4.1.2.2 Limitações

Alguns estudos podem não ter sido incluídos devido ao fato de que, apesar de as bases pesquisadas abrangerem uma grande parcela das publicações científicas de maior qualidade, não é possível cobrir sua totalidade e ainda, algumas pesquisas podem estar relacionadas ao tema, porém não circunscritas à população, conceito e contexto (PCC) adotados neste trabalho. Vale notar que na análise bibliométrica das citações, os artigos que deram origem aos trabalhos na área, tanto em relação aos métodos quanto aos indicadores dos modelos, que foram referidos pelos artigos selecionados correspondem àqueles que também foram utilizados na presente revisão da literatura, o que confere representatividade à amostra selecionada.

Ademais, outra limitação se refere a não terem sido utilizados artigos da chamada literatura cinzenta (*Grey Literature*), na medida em que sua busca nesse ponto inicial da pesquisa seria evitada de subjetividade e poderia gerar um viés na

análise. Entretanto, tendo em vista que grande parte dessa literatura se encontra na base de relatórios técnicos e *working papers* das autoridades monetárias e órgãos que fazem parte do Sistema Financeiro Internacional, a análise destas pesquisas constitui uma fonte de evidências para descortinar as tendências e iniciativas que as aludidas instituições estão desenvolvendo no tema em tela.

Por fim, uma importante limitação se refere à consolidação dos indicadores, cuja classificação, embora realizada de forma criteriosa, está sujeita ao viés dos revisores. Adicionalmente, algumas variáveis carregam uma base interpretativa em seu cálculo, além de os critérios para determinar a significância do indicador serem diversos entre os autores dos estudos primários.

Entretanto, os achados não apresentam grande disparidade em relação aos estudos anteriores utilizados como benchmark e as pequenas diferenças podem ser explicadas pelo tempo decorrido. Portanto, apesar de ser possível algum viés interpretativo, o rigor teórico e a semelhança com estudos anteriores conferem aos indicativos uma possibilidade de acerto razoável.

#### 4.1.2.3 Considerações

O objetivo dessa revisão de escopo foi mapear a produção científica relativa a Sistemas de Alerta Precoce para crises financeiras sistêmicas visando extrair o conhecimento por meio dos conceitos-chave envolvidos em seu desenvolvimento e utilização. Essa extração se deu por meio da identificação, mapeamento e síntese das evidências encontradas na literatura relacionadas aos padrões de alerta, métodos, técnicas e ferramentas utilizados e das tendências de construção e emprego dos aludidos sistemas.

A pesquisa corroborou a escolha do método tendo em vista que, especificamente em relação à população, ao conceito e ao contexto estabelecidos, o corpo de evidências se mostrou novo, heterogêneo e complexo. Conseqüentemente, essa primeira revisão contribui com indicativos e tendências que podem ser úteis para os tomadores de decisão e, principalmente para o desenvolvimento do modelo desta dissertação.

Nesse sentido, observou-se que existem alguns indicadores que vêm sobressaindo e apresentam maior relevância para a previsão de crises financeiras e

outros, de eficácia comprovada, que foram revalidados nesta pesquisa. Além disso, as tendências apontam para a intensificação de uso das técnicas de ML e do aumento da capacidade de análise de dados, configurando um movimento dos Sistemas de Alerta Precoce que se afasta das abordagens tradicionais e se aproxima da Inteligência Artificial.

#### 4.2 USO DE ML EM EWSs PARA CRISES FINANCEIRAS

A primeira revisão de literatura teve como objetivo mapear a produção científica relativa a EWSs para crises financeiras sistêmicas visando extrair o conhecimento por meio dos conceitos-chave envolvidos em seu desenvolvimento e utilização. Para a aludida revisão foi utilizado o método de revisão de escopo e seu relatório seguiu estritamente o protocolo PRISMA-SCR (Tricco *et al.*, 2018).

Conquanto haja recomendação explícita sobre a possibilidade de inclusão da dita *Grey Literature* (GL), optou-se, na revisão de escopo, por não incluí-la como fonte, tendo em vista que essa primeira busca priorizou os trabalhos científicos indexados, portanto, as bases acadêmicas. A propósito, a definição mais amplamente difundida e utilizada sobre o termo foi cunhada na Terceira Conferência Internacional sobre *Grey Literature* realizada em 1997, a chamada definição de Luxemburgo, segundo a qual, GL é: “[...] aquela que é produzida em todos os níveis de governo, acadêmicos, empresas e indústrias em formatos impressos e eletrônicos, mas que não é controlado por editoras comerciais.” (GL’97, 1998, p. iii, tradução própria).

A revisão de escopo revelou importantes apontamentos e oportunidades de pesquisa que foram explorados no presente trabalho, a exemplo da não inclusão de evidências da GL. Apesar de ter sido apresentada como limitação, que se justificava no contexto da referida revisão, foi revelada como uma fonte de evidências para descortinar as tendências e a prática relacionadas ao tema, tendo em vista que grande parte dessa literatura se encontra na base de relatórios técnicos e *working papers* das autoridades monetárias e órgãos que constituem o sistema financeiro global.

Outro achado significativo, que serviu de ponto de partida para a presente revisão, foi a intensificação de uso das técnicas de ML no desenvolvimento de EWSs. A GL demonstra ser uma fonte promissora de evidências no sentido de verificar essa

tendência, porquanto representa o estado da prática, de onde se pôde verificar na revisão de escopo que surgiram as inovações no tema.

Diante das oportunidades que a GL apresenta e tendo em vista que a literatura indexada (*White Literature*) foi coberta na referida revisão de escopo, esta segunda revisão se concentrou apenas nas fontes de dados de GL. Ademais foi adotada essa estratégia para alcançar o objetivo de corroborar ou contrapor os aludidos apontamentos e oportunidades encontrados na literatura científica com as experiências práticas disponíveis.

Tendo em vista que a questão deste trabalho, além de multidisciplinar, está ligada à área de Engenharia do Conhecimento, buscou-se referência na Engenharia de *Software* para seleção do método de pesquisa. Nesse sentido e tendo como paradigma a abordagem EPB, recorreu-se à pesquisa de Kitchenham *et al.* (2004), que propuseram o conceito de Engenharia de *Software* Baseada em Evidências (EBSE) com o intuito de prover meios para que as evidências atuais da pesquisa possam ser integradas à experiência prática disponível no âmbito das instituições que compõem o sistema financeiro internacional.

A despeito do alinhamento estrito do objetivo da EBSE à presente pesquisa, o método proposto pelos autores, da mesma forma que o *PRISMA* (Tricco *et al.*, 2018), apenas tangencia a inclusão da GL e não fornece um guia sistemático para conduzir estudos a partir desse tipo de fonte. A partir do reconhecimento da importância de utilização da GL e da ausência de um conjunto de diretrizes específicas capaz de garantir a qualidade dos processos de revisão sistemática e seus resultados, Garousi *et al.* (2019) se basearam no trabalho de Kitchenham and Charters (2007) para apresentar um guia para a chamada *Multivocal Literature Review* (MLR), que contempla a inclusão desse tipo de evidências ao lado da literatura formal e cujo protocolo está resumido no apêndice C.

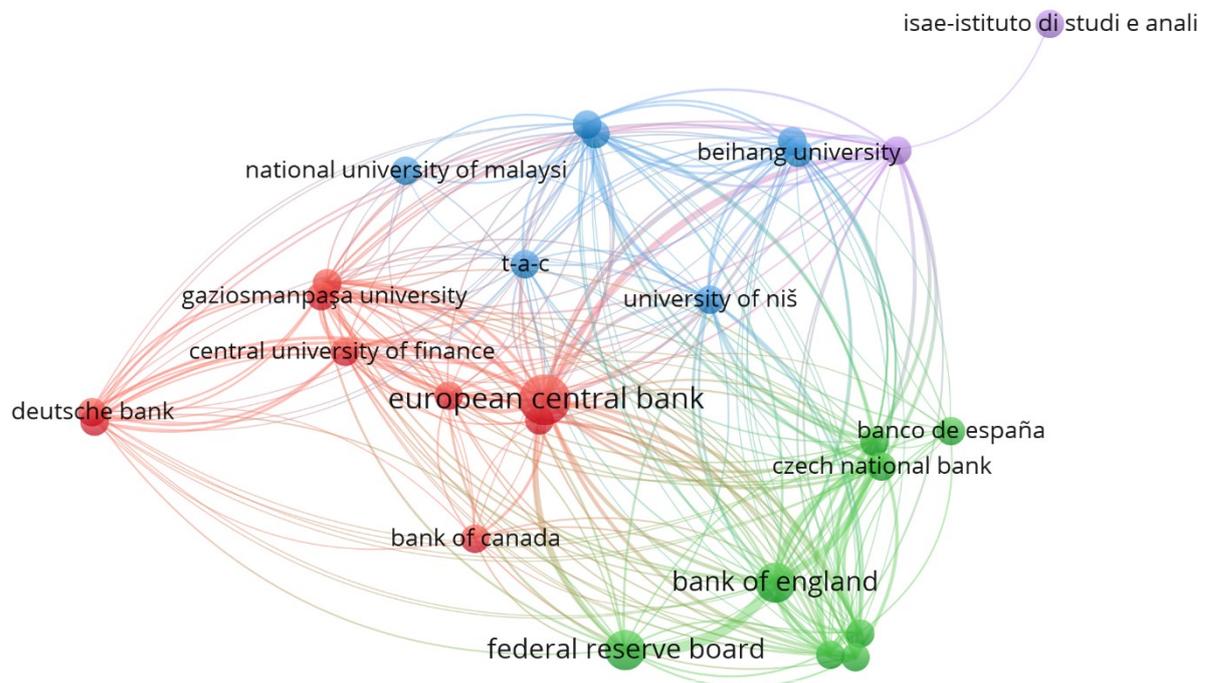
#### **4.2.1 Resultados**

Primeiramente, a seleção das bases de dados foi direcionada pelo contexto desta pesquisa, que se restringe aos órgãos internacionais e autoridades monetárias que regulam o sistema financeiro global. Essa restrição, tendo em conta que são instituições extremamente técnicas e rigorosas, ao mesmo tempo em que traz uma

certa segurança quanto à qualidade dos estudos, traz também uma demanda por rigor metodológico no que se refere às bases a serem pesquisadas.

Nesse sentido, optou-se por construir, primeiramente, uma rede bibliométrica de relações de citação a partir das organizações dos estudos considerados relevantes na revisão de escopo que serviu de base para esse segundo trabalho de revisão. Conforme se pode observar por meio da Figura 16, os nós centrais se referem a bancos centrais e instituições supragovernamentais.

Figura 16 - Rede bibliométrica de organizações



Fonte: Desenvolvido pelo autor por meio do *software VOSviewer*

A análise bibliométrica reforça o indício de que os maiores interessados no desenvolvimento de EWSs para crises financeiras sistêmicas são essas organizações. A propósito, os trabalhos seminais mais citados na literatura referente a estes sistemas (Kaminsky *et al.*, 1998 e Frankel & Rose, 1996) foram desenvolvidos no âmbito do Federal Reserve, os estudos mais referenciados a respeito do uso de ML nesse contexto (Alessi & Detken, 2018; Holopainen & Sarlin, 2017), no Banco Central Europeu; e ainda, um dos estudos mais profundos a respeito de Crises Financeiras Sistêmicas (Laeven & Valencia, 2013, 2018), no Fundo Monetário Internacional.

Finalmente, a seleção das bases para essa revisão de literatura priorizou as vinte instituições mais bem classificadas no *ranking* de bancos centrais IDEAS/RePec<sup>6</sup>. Cabe ressaltar que a busca na base do *Federal Reserve System* foi realizada no sítio do *Federal Reserve Board*, tendo em vista que foi possível verificar que o último concentra as principais fontes de evidências do sistema, o que resultou na seleção de onze bases para a execução da busca.

Os critérios de elegibilidade foram estabelecidos com base nos objetivos da pesquisa e do referencial teórico relacionado ao tema. Nesse sentido, os termos que resumem a questão de pesquisa, por meio de população, conceito e contexto (PCC), restringem os trabalhos elegíveis àqueles que tratam de EWSs que utilizam técnicas de ML para crises financeiras.

Também de acordo com o referencial teórico, é possível deduzir que o tema é relativamente novo, na medida em que passa a ter relevância a partir do início dos anos 2000, ademais, não vem sendo explorado de forma consistente em língua portuguesa. Consequentemente, a opção foi por fazer a busca pelos termos em inglês e sem limitação temporal, visando alcançar a maior extensão possível da produção científica disponível.

Tendo em vista que o âmbito da pesquisa se restringe aos órgãos do sistema financeiro global, não foi incluído o termo referente a crises financeiras sistêmicas e a devida triagem foi realizada manualmente a partir do resultado da busca. Quanto ao tipo de documento, optou-se por limitar a busca, quando possível (quando não, a limitação foi aplicada no processo de triagem), a artigos, relatórios técnicos e *working papers*, tendo em vista tanto o rigor metodológico quanto o fato de se buscar a experiência prática e não ideias, impressões ou mesmo apresentações e discursos.

De acordo com Garousi *et al.* (2019), a determinação do limite para se encerrar a busca em GL quando há um extenso volume de dados não é simples, diante dessa questão, os autores apresentam três diferentes estratégias, a saber: Saturação teórica, Limitação do esforço e Esgotamento de evidências. Optou-se

---

<sup>6</sup> Disponível em: <https://ideas.repec.org/top/top.central.html>, acesso em: 02/02/2022

IDEAS é o maior banco de dados bibliográfico dedicado à Economia e disponível gratuitamente na Internet. Com base no *RePEc*, indexa mais de 3.900.000 itens de pesquisa, incluindo mais de 3.500.000 que podem ser baixados em texto completo.

*RePEc* é um grande esforço voluntário para melhorar a disseminação gratuita da pesquisa em Economia, que inclui metadados bibliográficos de mais de 2.000 arquivos participantes, incluindo todas as principais editoras e agências de pesquisa.

nesse trabalho por seguir a mesma estratégia dos autores, ou seja, nas buscas que retornaram um número elevado de registros, a extração se limitou a 100 registros a não ser que a página seguinte ainda revelasse resultados relevantes, o que configura uma regra híbrida limitada ao esforço robustecida por um critério de parada do tipo exaustivo.

Em seguida, a busca foi executada individualmente nas bases e a seleção inicial foi feita manualmente a partir da leitura do resumo e do título das evidências encontradas a partir dos critérios de elegibilidade. O quadro a seguir resume a quantidade de registros e fontes primárias obtidas em cada base após essa triagem inicial.

Quadro 4 - Quantidade de resultados primários da busca

Base / site	Registros	Fontes
Fundo Monetário Internacional ( <a href="http://www.imf.org">www.imf.org</a> )	47	13
Banco Central Europeu ( <a href="http://www.ecb.europa.eu">www.ecb.europa.eu</a> )	100*	13
Federal Reserve Board ( <a href="http://www.federalreserve.gov">www.federalreserve.gov</a> )	100*	3
Bank for International Settlements ( <a href="http://www.bis.org">www.bis.org</a> )	33	2
Banca d'Italia ( <a href="http://www.bancaditalia.it">www.bancaditalia.it</a> )	18	0
Banco de España ( <a href="http://www.bde.es">www.bde.es</a> )	2	0
Bank of England ( <a href="http://www.bankofengland.co.uk">www.bankofengland.co.uk</a> )	100*	3
Banque de France ( <a href="http://www.banque-france.fr">www.banque-france.fr</a> )	100*	0
Banco de la Republica de Colombia ( <a href="http://www.banrep.gov.co">www.banrep.gov.co</a> )	0	0
Bank of Canada ( <a href="http://www.bank-banque-canada.ca">www.bank-banque-canada.ca</a> )	10	0
Deutsche Bundesbank ( <a href="http://www.bundesbank.de">www.bundesbank.de</a> )	18	1
<b>Total</b>	<b>528</b>	<b>35</b>

\* limite de registros determinado conforme regra sugerida por Garousi *et al.* (2019).

Fonte: Elaborado pelo autor

Após a triagem inicial, restaram 35 trabalhos para leitura integral, dos quais, 20 não foram considerados elegíveis, dentre eles, cinco não tratavam nem de EWS, nem de crises financeiras; quatro não propunham um EWS; dois não representavam um EWS para antecipar crises financeiras; quatro não foram desenvolvidos com a utilização de ML; um não tratava nem de ML, nem de crises financeiras; um repetia outra publicação; um foi publicado em duas bases diferentes; um estava contido em outro estudo considerado na amostra; e um era o “*draft*” de um *working paper* presente na amostra. A seguir, as 15 fontes de evidências resultantes desse processo, foram submetidas aos requisitos obrigatórios e cinco não comparavam o desempenho dos

métodos baseados em ML aos tradicionais, como resultado; portanto, a amostra final consta de 10 trabalhos.

Como resultado do processo de leitura e análise da amostra objeto da pesquisa, as fontes de evidência foram padronizadas e sintetizadas para responder à questão e aos objetivos da pesquisa, conforme Quadro 5 a seguir:

Quadro 5 - Quadro analítico

(continua)

<b>Autores</b>	<b>Métodos*</b>	<b>Variáveis</b>	<b>Causa / Efeito</b>
<i>Alessi et al.</i>	<i>Probit, Logit, Signaling Approach; BMA; CART; RF</i>	De acordo com os modelos, segundo as seguintes categorias: Globais; Setor bancário; Dívida / Balanço governamental; Conta corrente; Serviço da dívida; Taxas de Juros / inflação; PIB; Preços de Ativos; Preços de imóveis; Crédito	-
<i>Beutel et al.</i>	<i>Logit; KNN; Decision trees; RF; SVM</i>	Crédito; Preços de imóveis; Preços de Ativos; PIB; Inflação; Taxa de juros; Formação bruta de capital fixo; Conta Corrente; Taxa de câmbio; Preços do petróleo	-
<i>Bluwstein et al.</i>	<i>Logistic regression; RF; Extremely randomised trees; SVM; ANN; Decision Tree</i>	Inclinação da curva de rendimentos de títulos públicos; Crédito; Índice de Preços ao Consumidor (CPI); Serviço da dívida; Consumo; Investimento; Dívida Pública; Base Monetária; Preços de Ações; Conta corrente	<i>Shapley values</i>
IMF	<i>Signal extraction; Logit (Elastic Net, Ridge e LASSO), RF (Balanced random forest, RUSBoost, AdaBoost e Gradient Boosting), SVM</i>	De acordo com os modelos e tipos de crises, segundo as seguintes categorias: Global; Externa; Financeira; Real; Fiscal	<i>Shapley values</i>
<i>Fouliard et al.</i>	<i>Dynamic Probit; Panel Logit; BMA; General Additive Model; RF; SVM</i>	De acordo com os modelos, segundo as seguintes categorias: Dívida, PIB, Desemprego, Investimento, Crédito, Taxas de juros, Base Monetária, Preços de ativos, índice de “sentimento econômico”, Preços de <i>commodities</i> ; Preços de imóveis, Desequilíbrios externos	-

Quadro 5 - Quadro Analítico

(conclusão)

<b>Autores</b>	<b>Métodos*</b>	<b>Variáveis</b>	<b>Causa / Efeito</b>
Hellwig	<i>Logit; Elastic net; RF; XG boost</i>	PIB; Reservas; Conta Corrente; Exportação / Importação; Taxa de Câmbio; Dívida Externa; Serviço da Dívida; Dívida Pública; Política	-
Holopainen & Sarlin	<i>Signal extraction; Linear Discriminant Analysis; QDA; Logit; Logit LASSO; Naive Bayes; KNN; Classification trees; RF; ANN; ELM; SVM</i>	Preços de imóveis; Conta corrente; Dívida pública; Empréstimos / renda; Crédito; PIB; Rendimentos dos Títulos Públicos; Inflação; Preços de Ações; Preços de imóveis; <i>Credit to GDP</i>	-
Jarmulska	<i>RF; Logit</i>	Taxas de juros; PIB; Preço do petróleo; VIX (índice de Volatilidade); Taxa de câmbio real; Conta corrente; Exportações globais; Formação bruta de capital fixo; Índice de Preços ao Consumidor (CPI); Consumo real; Taxa de câmbio nominal; Crédito; Balanço governamental; Dívida Pública; Serviço da dívida; Desemprego; Produtividade do trabalho	<i>Shapley values; Breiman's variable importance</i>
Puglia & Tucker	<i>Probit; RF; XGBoost; LightGBM; SVM; ANN</i>	Curva de rendimentos de títulos do Tesouro (ACM5D e inclinação); Preços de Ações; Crédito; NFCI (Índice de Condição Financeira); <i>Conference Board's Leading Economic Index - LEI e Survey of Professional Forecasters – SPF</i> (índices de Probabilidade de Recessão)	<i>Shapley values (SHapley Additive exPlanations - SHAP)</i>
Suss & Treitel	<i>Logit; KNN; RF; Boosting; SVM</i>	Ações; Inflação; Rendimento; PIB; Desemprego; Outras variáveis financeiras (micro)	<i>Shapley values</i>

\*Onde: ANN - Artificial Neural Network; BMA – Bayesian Model Averaging; CART – Classification and Regression Tree Methodology; ELM – Extreme Learning Machines; KNN – k-nearest Neighbors; QDA – Quadratic Discriminant Analysis; RF – Random Forest; SVM – Support vector machines

Fonte: Elaborado pelo autor

## 4.2.2 Discussão

Nessa revisão, conforme fluxo demonstrado no Apêndice D, foram avaliados 10 estudos primários, publicados entre 2015 e 2021, que abordam o uso de técnicas de ML no desenvolvimento de EWSs para crises financeiras. A pesquisa encontrou uma área ainda em desenvolvimento, cujos primeiros artigos foram publicados no início da década de 2010 e que está ganhando importância na medida em que os episódios sistêmicos se avolumam e a complexidade em determiná-los também cresce.

### 4.2.2.1 Sumário das evidências

A pesquisa indicou certa homogeneidade em relação ao desenvolvimento dos trabalhos, diferindo, porém, ligeiramente no que tange aos métodos analisados, bem como às técnicas utilizadas para comparar as ferramentas, nesse caso de forma mais profunda, o que talvez explique os diferentes resultados encontrados. Todavia, foi possível responder à questão de pesquisa por meio dos importantes achados, que se encontram relatados a seguir de acordo com os objetivos específicos estabelecidos.

Embora alguns estudos analisados apontem em direções diferentes, muitas vezes até opostas, ao compararem o desempenho das técnicas ML com o de métodos tradicionais, parece haver certo consenso em relação às vantagens e desvantagens relacionadas a cada abordagem. Suss & Treitel (2019), por exemplo, afirmam que abordagens convencionais são incapazes de explicar interações complexas e não linearidades em contraste com a flexibilidade das ferramentas de ML.

Na mesma linha, o Fundo Monetário Internacional (IMF, 2021) aponta que as técnicas de ML tendem a ser melhores para lidar com interações complexas entre muitos preditores. Por outro lado, também revela que os padrões capturados por modelos desenvolvidos por meio de ML não são necessariamente fáceis de interpretar, especialmente, porque economistas e formuladores de políticas ainda não estão familiarizados com esse conjunto de ferramentas.

Bluwstein *et al.* (2020) acrescentam que os modelos de ML analisados em seu estudo, quando bem calibrados e treinados, se aproximam de qualquer função bem-comportada. Contudo, sua alta flexibilidade normalmente os torna difíceis de interpretar, em particular, no que tange a determinar quais variáveis conduzem as previsões do modelo e o peso da relação funcional entre elas.

#### 4.2.2.1.1 *Machine Learning* x técnicas tradicionais

Alessi *et al.* (2015) promovem um exercício conjunto (a chamada “horse race”) com os principais *frameworks* empíricos de EWSs desenvolvidos no âmbito do trabalho da MaRs<sup>7</sup> visando lançar alguma luz sobre suas vantagens e desvantagens relativas. O estudo não foca especificamente na comparação de performance entre técnicas tradicionais e de ML, mas parece ter sido uma das primeiras tentativas nesse sentido e apresenta como principal conclusão o fato de as abordagens multivariadas gerarem resultados de alerta precoce potencialmente muito úteis e oferecerem melhorias consideráveis em relação às univariadas.

Holopainen & Sarlin (2016) também promovem o mesmo tipo de exercício, entretanto com o objetivo de efetuar a aludida comparação e demonstram que as abordagens estatísticas convencionais são superadas por métodos de ML, como *k-nearest neighbors* e redes neurais, e, particularmente, por abordagens de agregação de modelos. Fouliard *et al.* (2021) utilizam uma metodologia de aprendizado on-line para realizar uma “horse race” entre modelos especialistas diversos e agregá-los para produzir uma previsão ideal, independentemente da natureza do processo de geração de dados, entretanto, o resultado é inconclusivo no que se refere à diferença de performance entre as técnicas.

Na nota técnica do FMI (IMF, 2021), também é possível encontrar resultados similares que apontam que os modelos de ML superam regularmente os métodos econométricos clássicos. Entretanto, diante da segmentação dos modelos por tipos de crise, os autores apresentam uma exceção no que se refere a crises do setor

---

<sup>7</sup> *Macroprudential Research Network (MaRs)* é uma rede interna para pesquisa macroprudencial, lançada em 2010 pelo Sistema Europeu de Bancos Centrais, composto pelos 27 bancos centrais nacionais da União Europeia (UE) e pelo Banco Central Europeu. Disponível em: [https://www.ecb.europa.eu/pub/economic-research/research-networks/html/researcher\\_mars.en.html](https://www.ecb.europa.eu/pub/economic-research/research-networks/html/researcher_mars.en.html), acesso em: 03 fev. 2022.

externo, em que a abordagem de extração de sinais apresentou um resultado melhor em casos específicos para economias avançadas.

Hellwig (2021), por seu turno, ao avaliar a capacidade preditiva *out-of-sample* de técnicas econométricas e de aprendizado de máquina para crises fiscais, demonstra que as abordagens de *Random Forest* superam sistematicamente os modelos estatísticos. Na mesma linha, Suss & Treitel (2019), afirmam que *Random Forest* é substancialmente e significativamente superior aos outros modelos estudados, tanto técnicas clássicas de regressão linear quanto de ML.

Os autores estimam as probabilidades de previsão *out-of-sample* usando um *design* de validação cruzada que leva em consideração várias fontes potenciais de viés para evitar vazamento de dados (*data “peeking”*) e o consequente resultado de desempenho excessivamente otimista. A propósito, Puglia & Tucker (2020) afirmam que as estimativas de validação cruzada obtidas por meio da técnica *k-folds* são tendenciosas de forma otimista, e as estratégias que eliminam o vazamento de dados produzem estimativas, possivelmente, mais realistas de precisão de previsão.

Nesse sentido, os autores propõem uma estratégia mais conservadora para estimar as probabilidades de previsão *out-of-sample* dos *spreads* de títulos do Tesouro e outras variáveis macroeconômicas e financeiras. Na análise realizada, a validação cruzada *k-folds* indica que a precisão de previsão do método de árvore de decisão é superior à das redes neurais, que por sua vez supera a da regressão *Probit*.

Entretanto, os autores ainda documentam que no método mais conservador (*Nested Time-Series - NTS*), o resultado se inverteu e indicou a superioridade do método *Probit* em relação às técnicas de ML. Por outro lado, afirmam que esse último resultado contrasta com um crescente corpo de literatura e sinalizam que a possível razão para isso se refere às características do esparso e relativamente pequeno conjunto de dados utilizado em dissonância com as técnicas de ML usadas, que foram desenhadas para bases de dados maiores.

Outra questão trazida no estudo é a tendência de *overfitting* em técnicas de ML, a menos que sejam controladas suficientemente por meio de um conjunto de hiperparâmetros. Beutel *et al.* (2018) também sugerem que o *overfitting* pode representar um desafio importante para alguns modelos de ML e adicionam que, mesmo para aqueles em que o ajuste *in-sample* não é estrito, seu desempenho *out-of-sample* é, na maioria dos casos, marcadamente inferior.

Os autores focam especificamente na comparação entre o desempenho preditivo obtido por modelos baseados em ML e por modelos convencionais e afirmam que os primeiros possuem uma maior capacidade preditiva *in-sample*, entretanto, afirmam que o inverso acontece nas previsões *out-of-sample*, na medida em que o método *Probit* apresenta uma performance consideravelmente superior. Entretanto, Jarmulska (2020) chega a um resultado diametralmente oposto e afirma que a técnica de validação cruzada empregada em seu estudo produz um parâmetro de penalização que maximiza a precisão da previsão *out-of-sample* do modelo e limita o problema de *overfitting*.

Beutel *et al.* (2018) conjecturam que as diferenças na amostra de treinamento empregada são um fator-chave dos resultados contrastantes encontrados em seu estudo. Acrescentam ainda que sua janela *out-of-sample* é naturalmente dominada pela crise financeira global de 2008 e que os resultados podem ser diferentes para outros conjuntos de dados ou outras técnicas de ML.

Um bom exemplo disso é o trabalho de Bluwstein *et al.* (2020), que compara um conjunto diversificado de modelos de ML e regressão logística em um conjunto de dados de longo prazo em validação cruzada *out-of-sample* e testes de previsão recursiva. Os autores demonstram que os modelos baseados em ML superam consistentemente a regressão logística na previsão de crises financeiras em um conjunto de dados macroeconômicos que abrange 17 países entre 1870 e 2016.

A abordagem utilizada ilustra como as técnicas de ML podem descobrir não linearidades e interações importantes que facilitam a predição, mesmo em situações caracterizadas por conjuntos de dados relativamente pequenos com observações limitadas do evento de interesse. Os modelos que apresentaram regularmente resultados mais precisos são baseados em árvores de decisão, a saber: *Extremely Randomised Trees* e *Random Forest*.

#### 4.2.2.1.2 Modelo de EWS

No âmbito do estudo realizado por Suss & Treitel (2019), *Random Forest* seria a técnica mais indicada para a construção de um EWS. Jarmulska (2020) segue no mesmo sentido e, além da performance superior em seu estudo, aponta também como vantagens sua robustez e eficácia, bem como sua relativa simplicidade na medida em que não requer muita parametrização, nem um banco de dados volumoso.

A mesma escolha é convalidada por Hellwig (2021), que acrescenta que para países em desenvolvimento de baixa renda, ampliar o conjunto de variáveis e deixar sua seleção para um algoritmo leva a ganhos consideráveis de precisão. Já para Beutel *et al.* (2018), um modelo *Logit* levando em conta os indicadores de crédito e preços de ativos, mas também os relacionados a desequilíbrios externos, teria sido capaz de emitir alertas relativamente precisos antes da crise financeira global de 2008 para grande parte dos países.

Com relação aos indicadores de crise, Alessi *et al.* (2015) encontraram evidências que sustentam a importância do crescimento do crédito ao setor privado. Fouliard *et al.* (2021), por sua vez, afirmam que há muita heterogeneidade entre os países em termos de quais métodos e variáveis depende a capacidade de previsão, portanto, não é conclusivo em relação ao melhor modelo.

Puglia & Tucker (2020) não são taxativos, entretanto, demonstram que os métodos de ML, devido a sua flexibilidade, são capazes de capturar a natureza não linear das distribuições empíricas conjuntas dos rendimentos de títulos de Tesouro e outros dados macroeconômicos e do mercado financeiro. Além disso, afirmam que, apesar do aludido desajuste das técnicas utilizadas às características da base de dados, por meio da parametrização, foi possível alcançar resultados de previsão alinhados à intuição financeira e econômica; na medida em que os modelos sinalizaram possibilidade de recessão a partir da estabilização dos *spreads* do Tesouro *versus* aperto das condições de crédito ou deterioração dos fundamentos macroeconômicos.

Além das variáveis macroeconômicas amplamente citadas na literatura, indicadores relacionados às taxas de juros de títulos do Tesouro começam a ganhar destaque como um importante indicador de crises financeiras em estudos mais recentes, a exemplo de Puglia & Tucker (2020) e Bluwstein *et al.* (2020), em linha também com evidências da revisão de escopo anterior (e.g. Guru, 2016 e Joy *et al.*, 2017). A propósito, Bluwstein *et al.* (2020) ressaltam que, embora o papel crucial do crédito seja um resultado estabelecido na literatura, o poder preditivo da curva de juros tem recebido muito menos atenção como indicador de alerta antecipado.

Os principais sinais de alerta precoce encontrados em seu estudo incluem crescimento elevado e prolongado do crédito doméstico em relação ao PIB e curva de juros plana ou invertida, especialmente quando os rendimentos nominais são baixos.

Todos os modelos estudados por Bluwstein *et al.* (2020) identificam consistentemente preditores semelhantes para crises financeiras com algumas variações ao longo do tempo, refletindo mudanças na natureza do sistema monetário e financeiro global nos últimos 150 anos, entretanto, o algoritmo *Extremely randomised trees* foi o que apresentou os melhores resultados preditivos.

Para Alessi *et al.* (2015), o uso de um conjunto de modelos multivariados pode ser uma boa opção para desenvolver instrumentos empíricos de polícia macroprudencial. Em direção similar, Holopainen & Sarlin (2016) reportam que os modelos alcançaram melhor desempenho preditivo ao utilizar procedimentos de agregação, em particular *ensemble learning* (*bagging e boosting*) para combinar métodos diferentes em um instrumento único.

Ao adotar estratégia análoga, Suss & Treitel (2019) reportam melhorias estatisticamente significativas em relação ao algoritmo *Random Forest* utilizado de forma isolada. Fouliard *et al.* (2021), por seu turno, propõem um sistema especialista que agrupa vários modelos por meio de uma regra de agregação (*Exponentially Weighted Average - EWA*) e defendem a estratégia como o melhor caminho para a construção de um EWS.

#### 4.2.2.1.3 Causa e efeito

Fouliard *et al.* (2021) reconhecem que seus modelos são incapazes de testar a causalidade, contudo reafirmam que é necessário que os resultados sejam interpretáveis para possibilitar a análise das autoridades macroprudenciais. A nota técnica do FMI (IMF, 2021) também advoga que as ferramentas de comunicação são parte fundamental de um EWS baseado em ML, essencialmente quando projetado para informar os formuladores de políticas e orientar suas decisões.

Para essa tarefa, os autores do relatório identificam que o método de valores de *Shapley*, originário da teoria dos jogos, está se tornando cada vez mais popular. Jarmulska (2020) adiciona que *Random Forest*, apesar de superar em performance preditiva os modelos *Logit*, oferece interpretabilidade dos resultados menor, o que representa uma limitação relevante para os economistas, que são os que mais podem se beneficiar de sua utilização para predição de crises.

Diante dessa questão, os autores recorrem aos valores de *Shapley* e à importância das variáveis de Breiman (Breiman, 2001) para fornecer um exemplo de como determinar quais variáveis explicativas contribuíram mais para o resultado obtido, permitindo assim minimizar o chamado efeito “caixa-preta”. Suss & Treitel (2019) corroboram que a vantagem de desempenho do algoritmo *Random Forest* vem com um custo de transparência em relação ao modelo *Logit* que, dependendo dos requisitos dos reguladores, pode superar os benefícios.

Para remediar essa desvantagem relativa, os autores utilizaram técnicas recentemente desenvolvidas para entender os *drivers* do algoritmo, computando e agregando valores de *Shapley* para fornecer uma medida da importância relativa de cada variável na condução de previsões. Bluwstein *et al.* (2020) igualmente asseveram que a abordagem de valores de *Shapley* demonstra como a preocupação da “caixa-preta” ligada à aplicação prática de modelos de ML à formulação de políticas pode ser superada.

Mais precisamente, a probabilidade de crise prevista para cada observação individual é decomposta em uma soma de contribuições de cada preditor, ou seja, seus valores de *Shapley*, o que permite aos autores entender e demonstrar quais variáveis estão conduzindo cada previsão. Similarmente, Puglia & Tucker (2020) utilizam o *framework SHapley Additive exPlanations* – SHAP (Lundberg & Lee, 2017), bem como os testes de McNemar e Q de *Cochrane* para decompor as previsões e analisar a importância das variáveis em cada ciclo.

#### 4.2.2.2 Limitações

As limitações dessa revisão se referem às características peculiares da GL, notadamente ao fato de se apresentar em formatos variados, o que dificulta sua extração, síntese e análise. Nesse sentido, em primeiro lugar, é possível perder evidências significativas pois a busca acaba sendo, e foi no caso desse estudo, realizada de forma quase artesanal e sujeita a erro humano.

Some-se a isso, o fato de haver pouca orientação específica disponível para realizar pesquisas em GL e muitas vezes esse processo é feito de forma *ad hoc*. Para atenuar esse risco, além do apoio de uma metodologia de pesquisa rigorosa, foram realizadas uma seleção minuciosa e uma extensa busca apoiada em critérios de seleção sólidos, o que traz a confiança de que as fontes selecionadas representam o extrato do que há de melhor no conhecimento relacionado ao tema da pesquisa.

Outra questão que impacta as pesquisas em GL é a generalização dos resultados encontrados para um contexto mais amplo. O que no caso específico desta pode gerar menos preocupação pelo fato de que se tomou o cuidado de estabelecer critérios de elegibilidade e de qualidade, bem como requisitos de relevância que não permitem a inclusão de estudos que não utilizam técnicas objetivas e verificáveis para medir o desempenho dos modelos.

Ademais, outro ponto forte é que as fontes de evidências, apesar de não constituírem trabalhos finais ou revisados por pares, foram extraídos de forma criteriosa em bases de instituições que tem por tradição e até requisito de entrada a alta qualidade técnica de seu corpo funcional, conseqüentemente de seus trabalhos. Prova disso é que os trabalhos seminais e as grandes inovações na área, eminentemente, provém de estudos que tiveram suas primeiras publicações em *working papers* e relatórios técnicos de pesquisadores ligados a essas organizações, conforme demonstrado na subseção 4.2.1 e, particularmente, na Figura 16.

Outra limitação, que impacta qualquer tipo de revisão literária, mas em especial uma realizada integralmente em GL é a validade interna, vez que não existe ainda na literatura um “padrão-ouro” para a realização de pesquisas nesse tipo de fonte. Entretanto, dois fatores atenuantes aumentam a validade interna da pesquisa, o primeiro é o rigor metodológico aqui utilizado e o segundo é que a revisão foi baseada em um trabalho anterior de revisão de escopo em literatura científica e terminou por corroborar e complementar os achados e tendências apontados com base na prática dos órgãos do sistema financeiro global.

Por fim, a validade das conclusões é uma questão a ser avaliada na medida em que toda a revisão foi realizada em um campo de pesquisa homogêneo de instituições que contam com convicções filosóficas e formação técnico-científica que muitas vezes (mas nem sempre) convergem. Para isso, tomou-se o cuidado de, além de apresentar os resultados de forma sintética, realizar uma discussão qualitativa, fazendo os autores “conversarem”, em especial, aqueles que apresentaram visões divergentes.

#### 4.2.2.3 Considerações

O objetivo dessa revisão de literatura foi mapear o conhecimento empírico para verificar, com base na prática dos órgãos do sistema financeiro global, se EWSs que utilizam técnicas de ML apresentam uma performance preditiva para crises financeiras superior àqueles desenvolvidos sobre técnicas tradicionais. Essa extração de conhecimento se deu por meio da identificação, mapeamento e síntese das evidências encontradas na literatura relacionadas aos padrões de alerta, métodos, técnicas e ferramentas utilizados e das tendências de desenvolvimento e emprego dos aludidos sistemas.

A revisão corroborou a escolha do método na medida em que, apesar da complexidade em se pesquisar a GL, chegou-se a um resultado bastante representativo e revelador a respeito do problema de pesquisa, minimizando os vieses e trazendo o que há de mais relevante na prática relacionada ao tema. Nessa medida, o presente trabalho contribui com resultados relevantes que podem ser úteis para os tomadores de decisão e, principalmente para o desenvolvimento do modelo desta dissertação.

A propósito, o trabalho de revisão apresentou a seguinte questão de pesquisa: “*Machine Learning* melhora o desempenho dos Sistemas de Alerta Precoce para crises financeiras sistêmicas?”. Não obstante as limitações apresentadas, existe um forte indicativo e uma razoável uniformidade no entendimento a partir das evidências pesquisadas que a capacidade preditiva destes sistemas é aprimorada com a utilização das técnicas de ML.

Quanto ao método que apresentou uma melhor performance, os algoritmos derivados de árvores de decisão, em particular, *Random Forest* e suas derivações foram as que apresentaram um maior potencial. Há que se atentar, contudo, para a maior limitação a sua adoção, que se refere à reputação de “caixa-preta” de grande parte das técnicas utilizadas e ainda, à estrutura complexa, características que trazem resistência a seu uso por parte dos tomadores de decisão e formuladores de políticas públicas.

Contudo, a questão da transparência das relações de causa e efeito das variáveis preditivas e de sua interpretação já apresenta bastante evolução prática e, dentre as técnicas utilizadas, o método de valores de *Shapley* parece ser uma tendência de solução para equacionar essa deficiência. Como se pode depreender, os estudos sobre o uso das técnicas de ML em EWSs apresentam infinitas possibilidades e descortinam um campo ainda em pleno desenvolvimento.

Quanto aos indicadores, na construção de novos EWSs, há uma propensão a explorar o potencial de novos indicadores, como os ligados às taxas dos títulos públicos e, por sua vez, aqueles já testados e estabelecidos também mantêm sua importância. Adicionalmente, talvez haja uma tendência em aproveitar a capacidade computacional e a das ferramentas de Inteligência Artificial para trabalhar com um maior volume de dados e indicadores e até diferentes métodos, para assim, aumentar também a capacidade de predição dos Sistemas de Alerta Precoce.

Finalmente, o desenvolvimento e aplicação de ML na construção de EWSs representa ainda uma vasta fonte de trabalhos futuros, tanto em relação a novos métodos, quanto na busca por indicadores que possam ser mais efetivos em antecipar as crises financeiras sistêmicas. Para os formuladores de políticas públicas em geral e macroprudenciais em particular, o estímulo ao uso destes sistemas, e nomeadamente, a aplicação de ML representam um enorme potencial de desenvolvimento na tomada de decisão com base em evidências e maior entrega de valor público.

## 5 APRESENTAÇÃO DO MODELO

O modelo proposto (*InCrAISys - AI system to early indicate financial crisis*) neste capítulo se propõe a sinalizar precocemente a ocorrência de crises financeiras sistêmicas a partir da extração de conhecimento de um extenso conjunto de dados macroeconômicos. A abordagem utilizada se propõe a tratar por meio de técnicas de ML uma questão posicionada como um problema de classificação.

Para isso, são apresentados a seguir os componentes do modelo, selecionados com base na identificação das tendências e melhores práticas relativas a Sistemas de Alerta Precoce para crises financeiras sistêmicas. Tais evidências foram obtidas por meio da extração do conhecimento empírico dos órgãos do sistema financeiro global, precedida ainda por uma revisão de escopo que mapeou a produção científica relacionada ao tema.

O modelo de sistema de alerta precoce proposto é detalhado a partir de suas etapas de construção, quais sejam: extração e preparação dos dados; seleção e engenharia de atributos; treinamento do modelo; calibração dos hiperparâmetros; e teste e validação do modelo.

A Figura 17 ilustra o modelo proposto por meio de uma metáfora com o mecanismo de um relógio, segundo seus componentes, representados como engrenagens interconectadas que se ativam e “despertam” em resposta a sinais de crise financeira. Essa representação simbólica enfatiza a interdependência e a sequência das etapas do modelo, destacando sua capacidade de integrar diferentes elementos para colaborar com o aprimoramento da capacidade preditiva de crises financeiras.

### 5.1 COMPONENTES DO MODELO

O produto desta pesquisa não se posiciona como um sistema, todavia como um modelo que aplica o algoritmo *Random Forest* sobre uma base abrangente de informações macroeconômicas e financeiras para extrair conhecimento por meio de atributos. Esse conhecimento visa fornecer sinais antecipados de possíveis crises financeiras e indicar por meio de um método de explicação quais características têm mais peso na previsão, conseqüentemente, apoiar a tomada de decisão com base em

evidências das autoridades monetárias em especial e outros públicos de interesse que dependam desse tipo de informação.

Figura 17 - Representação do modelo



Fonte: Desenvolvido pelo autor por meio da IA Generativa DALL-E

### 5.1.1 Base de dados

Tendo em vista que a pesquisa de Bluwstein *et al.* (2020) corrobora grande parte dos achados da revisão da literatura realizada no presente trabalho, optou-se por utilizar o *Jordà-Schularick-Taylor Macroeconomy Database - JSTDatabase* (Jordà *et al.*, 2017), porém em seu release mais recente. A referida base, em seu release 6, lançado em 2022, apresenta algumas mudanças em relação à versão anterior, dentre as quais, pode-se destacar: a descontinuação de algumas séries do FMI; a adição da Irlanda ao conjunto de dados; uma ampla revisão do PIB e séries relacionadas; e a adição de três novas variáveis macroeconômicas com base em estudos recentes.

O *JSTDatabase* resulta de um extenso esforço de coleta de dados que unifica em uma abrangente fonte de dados que abarca uma grande parte da produção global de informações macroeconômicas e financeiras antes dispersas. Disponibilizado com acesso aberto, o banco de dados abrange 18 economias avançadas, e contém informações anuais sobre uma série de variáveis reais, nominais e binárias desde 1870 dispostas conforme os campos apresentados no quadro a seguir.

Quadro 6 - Descrição dos campos da base

(continua)

<b>Campo</b>	<b>Descrição</b>
<u>Identificação</u>	
year	Ano
country	País
iso	Código alfa do país
ifs	Código numérico do país
<u>Economia Real</u>	
pop	População
rgdpmad	PIB real per capita (PPP)
rgdpbarro	PIB real per capita (índice, 2005=100)
gdp	PIB Nominal (moeda local)
rconsbarro	Consumo real per capita (índice, 2006=100)
iy	Taxa de Investimento em relação ao PIB
unemp	Taxa de Desemprego (percentual)
wage	Salários (índice, 1990=100)
<u>Governo</u>	
revenue	Receita do Governo (nominal, moeda local)
expenditure	Despesa do Governo (nominal, moeda local)
debtgdp	Relação Dívida Pública/PIB
<u>Internacional</u>	
ca	Conta Corrente (nominal, moeda local)
imports	Importações (nominal, moeda local)
exports	Exportações (nominal, moeda local)
xrusd	Taxa de Câmbio em Dólar dos EUA (moeda local/USD)
<u>Política Cambial</u>	
peg	Ancoragem cambial (binário)
peg_strict	Ancoragem cambial estrita (binário)
peg_type	Tipo de ancoragem (BASE, PEG, FLOAT)
peg_base	Base de ancoragem cambial (GBR, USA, DEU, HYBRID, NA)
<u>JST trilemma instrument *</u>	
JSTtrilemmaIV	Instrumento para medir o impacto das intervenções monetárias
<u>Meios de Pagamento, Preços e Taxas de Juros</u>	
narrowm	Meios de Pagamento Restrito - M1 (nominal, moeda local)
money	Meios de Pagamento Ampliados (nominal, moeda local)
stir	Taxa de Juros de Curto Prazo (nominal, %aa)
ltrate	Taxas de Juros de Longo Prazo (nominal, %aa)
cpi	Índice de Preços ao Consumidor (índice, 1990=100)

Quadro 6 - Descrição dos campos da base

(conclusão)

<b>Campo</b>	<b>Descrição</b>
<u>Preços dos Imóveis</u>	
hpnom	Preços de Imóveis (índice, 1990=100)
<u>Dados de Crises (binário)</u>	
crisisJST	Crise Financeira Sistêmica (a partir do release 5)
crisisJST_old	Crise Financeira Sistêmica (até o release 4)
<u>Dados de Crédito (nominal, moeda local)</u>	
tloans	Crédito ao Setor Privado Não Financeiro
tmort	Crédito Hipotecário ao Setor Privado Não Financeiro
thh	Crédito às Famílias
tbus	Crédito às Empresas
<u>Dívida Corporativa</u>	
bdebt	Dívida corporativa (nominal, moeda local)
<u>Taxas de Retorno (nominais, moeda local)</u>	
eq_tr	Retorno Total de Ações
housing_tr	Retorno Total do Setor Imobiliário
bond_tr	Retorno Total de Títulos do Governo
bill_rate	Taxa de Títulos do Governo
rent_ipolated	1 se os rendimentos do aluguel de habitação forem interpolados, e.g. tempo de guerra
housing_capgain_ipolated	1 se os ganhos de capital imobiliário e os retornos totais forem interpolados, e.g. tempo de guerra
housing_capgain	Ganho de Capital do Setor Imobiliário
housing_rent_rtn	Retorno de aluguéis
housing_rent_yd	Rendimento de aluguéis
eq_capgain	Ganho de Capital
eq_dp	Rendimento de Dividendos
eq_capgain_interp	1 se o ganho de capital for interpolado para cobrir o fechamento da bolsa
eq_tr_interp	1 se o retorno total de ações for interpolado para cobrir o fechamento da bolsa
eq_dp_interp	1 se o retorno de dividendos for interpolado para cobrir o fechamento da bolsa
bond_rate	Taxa de Títulos do Governo
eq_div_rtn	Retorno de Dividendos
capital_tr	Retorno total sobre a riqueza
risky_tr	Retorno total em ativos de risco
safe_tr	Retorno total em ativos de renda fixa
<u>Balanço dos bancos</u>	
lev	Índice de Capital - Capital Ratio (%)
ltd	Liquidez dos bancos - LDR (%)
Noncore	Índice de financiamento não essencial (noncore) (%)

\* Instrumento para medir o impacto das intervenções monetárias no "trilema das finanças internacionais": taxas de câmbio, fluxos de capitais e política monetária (Jordà et. al., 2020).

Fonte: Elaborado pelo autor com base em Jordà *et al.* (2017)

A compilação dos dados envolveu colaborações internacionais, além de consultas a fontes históricas, estatísticas oficiais e bancos centrais. É importante destacar ainda que para cada uma das 2718 observações, o conjunto de dados contém uma variável binária que indica se houve crise financeira, com base em um extenso estudo teórico e empírico dos autores consolidado em uma série de produções técnicas e científicas.

### 5.1.2 Atributos

Da mesma forma que Bluwstein *et al.* (2020), entende-se que a identificação de padrões ou índices capazes de prever antecipadamente a ocorrência de crises financeiras é essencialmente um problema de classificação. Nesse sentido, recorreu-se à meticulosa modelagem realizada pelos autores e a definição do par ano/país como variável independente.

Nessa linha de modelagem, tendo em vista o rigor metodológico e a robustez da engenharia de atributos (*feature engineering*) realizada por Bluwstein *et al.* (2020), recorreu-se também a seu estudo visando definir o conjunto de atributos para alimentar o modelo. Assim sendo, por meio da extração e preparação dos dados brutos da base de dados (*JSTDatabase*) que será descrita na subseção “Construção do Modelo”, foram utilizados os seguintes preditores: inclinação da curva de juros (diferença entre taxas de curto e longo prazos); crédito (crédito ao setor privado não financeiro); índice de Preços; taxa de serviço da dívida (Taxa de juros de longo prazo sobre o PIB); consumo; investimento; dívida pública; meios de pagamento ampliados; conta corrente; inclinação da curva de juros global; e crédito global.

A inclinação da curva de juros foi mantida em níveis, enquanto o índice de preços e o consumo real per capita foram transformados em taxas de crescimento percentual dos índices fornecidos. Todas as outras variáveis foram expressas em termos de suas diferenças em relação ao PIB.

### 5.1.3 Técnica de *Machine Learning*

Neste modelo foi utilizada a classe *RandomForestClassifier*<sup>8</sup> da biblioteca *scikit-learn* do *Python* (também conhecida como *sklearn*), que implementa o algoritmo *Random Forest* (RF) para tarefas de classificação. A classe agrupa a lógica e as funcionalidades necessárias para treinar e usar modelos de RF para problemas de classificação.

A técnica foi escolhida devido a seu bom desempenho em tarefas de classificação, bem como ao alto potencial para detecção de crises financeiras como benefício de sua capacidade de detectar relacionamentos não lineares entre os atributos e a variável dependente. Além do mais, os resultados obtidos por algoritmos de RF podem ser mais facilmente explicados ao público-alvo que pode se beneficiar mais intensivamente da utilização do presente modelo para antecipação de crises financeiras.

Ademais a revisão de literatura realizada nesta pesquisa corrobora a aplicabilidade e o alto potencial do algoritmo RF por meio de diferentes abordagens para o problema em tela, achado validado empiricamente conforme demonstra a Tabela 2 a seguir, gerada a partir de um experimento de *cross-validation* entre as técnicas com os dados do presente modelo. Vale ressaltar que RF tem o intuito exatamente de reduzir o *overfitting* e os erros individuais de árvores de decisão por meio de sua agregação aleatória (Breiman, 2001).

Tabela 2 - Performance das técnicas de ML

Modelo	AUC	CA	F1	Prec	Recall
<i>Logistic Regression</i>	0.867	0.804	0.804	0.807	0.804
<i>Neural Network</i>	0.979	0.956	0.956	0.957	0.956
<i>Random Forest</i>	0.992	0.957	0.957	0.957	0.957
<i>Naive Bayes</i>	0.865	0.791	0.791	0.793	0.791
<i>Tree</i>	0.890	0.890	0.890	0.891	0.890

Fonte: Validação cruzada via *software Orange Data Mining*

<sup>8</sup> Disponível em: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>, acesso em 13 mar 2024

Adicionalmente, Holopainen & Sarlin (2017) reportam que os modelos de ML para previsão de crises financeiras alcançaram melhor desempenho preditivo ao utilizar abordagens de *ensemble learning*, como é o caso do algoritmo RF. Por fim, algumas características adicionais dessa técnica a tornam uma boa escolha para compor o modelo proposto neste estudo, quais sejam: interpretabilidade das técnicas baseadas em árvore de decisão; robustez e eficácia; relativa simplicidade; e pouca necessidade de parametrização.

#### 5.1.4 Método de explicação do modelo

Outro componente de suma importância para a construção de um modelo cuja aceitação e adoção requer transparência e interpretabilidade (Lipton, 2018) para gerar confiança é o método de explicação do modelo. O dilema entre obter níveis satisfatórios de desempenho preditivo de um modelo e a interpretabilidade de seus resultados, é uma questão comum na seleção de técnicas de ML.

A despeito de a técnica de ML selecionada (*Random Forest*) contar com estruturas de árvores de decisão como base, cuja interpretabilidade já é razoável, não é tarefa fácil determinar quais variáveis ou inter-relações têm mais peso nas previsões individuais do modelo. Outrossim, a complexidade dos problemas é diretamente proporcional à opacidade das técnicas de ML empregadas para sua resolução.

Em compensação, existe uma série de métodos de explicação de modelos disponíveis na literatura, dentre os quais o *framework Shapley Additive Explanations* (Lundberg & Lee, 2017) se mostrou mais adequado e difundido no campo de pesquisa do presente trabalho, conforme Quadro 5. Nesse contexto, os valores de *Shapley* (Shapley, 1953; Young, 1985) da teoria dos jogos cooperativos, são usados para calcular o benefício do modelo com inclusão de cada preditor, o que permite determinar quais têm mais peso em determinada previsão.

## 5.2 CONSTRUÇÃO DO MODELO

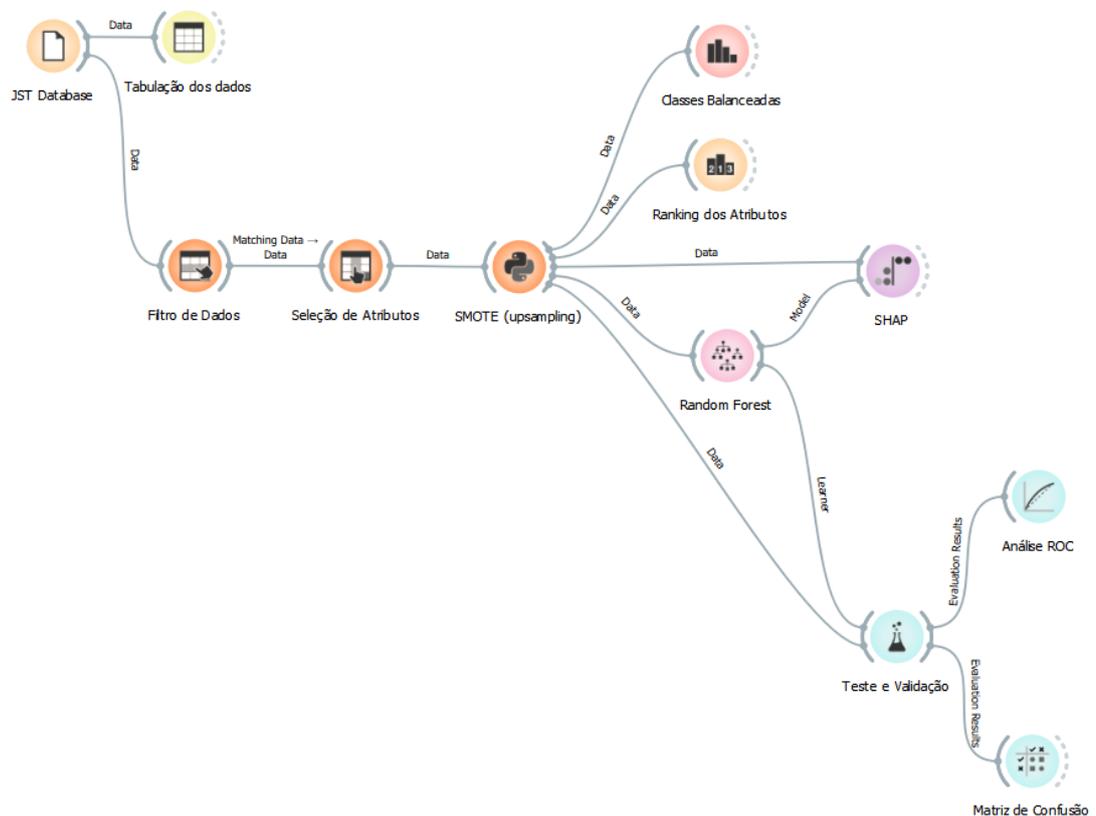
Tendo em vista o enfoque do EGC e respeitando o escopo declarado desta dissertação, não foi realizado um esforço de codificação de técnicas de ML para

desenvolvimento do modelo. Por outro lado, o foco do modelo está em aplicar técnicas de ML com o intuito de extrair conhecimento de bases de dados para identificar sinais comuns às crises financeiras capazes de detectar precocemente sua ocorrência.

A esse respeito, as ferramentas já apresentam um estado avançado de maturidade na descoberta de padrões em bases de dados numéricas, ademais já há muito trabalho desenvolvido em relação à codificação. Nesse sentido, a base tecnológica do modelo foi construída sobre uma plataforma de ML e *Data Mining*, denominada *Orange* (Demšar & Zupan, 2013), cuja arquitetura multicamadas suporta tanto programação por meio de *scripts* quanto desenvolvimento *no-code*.

O desenvolvimento do *Orange* se iniciou em 1997 e a continuidade se deu no Laboratório de Inteligência Artificial da Universidade de Ljubljana (Slovenia). Desde então, a ferramenta vem sofrendo constantes atualizações e incorporando novas funcionalidades que acompanham o avanço das áreas de *Machine Learning* e da Ciência de Dados de uma forma mais ampla. Quando este trabalho foi desenvolvido, o *Orange* se encontrava na versão 3.35.0 e as bibliotecas disponíveis já ofereciam suporte à construção do modelo ilustrado por meio da figura a seguir.

Figura 18 - Modelo *Orange*



Fonte: Tela impressa do software *Orange Data Mining*

### 5.2.1 Extração e preparação dos dados

Este passo envolve transformação dos dados financeiros brutos em um formato adequado à análise. O esforço inclui a limpeza dos dados, a seleção de variáveis relevantes e a normalização dos dados.

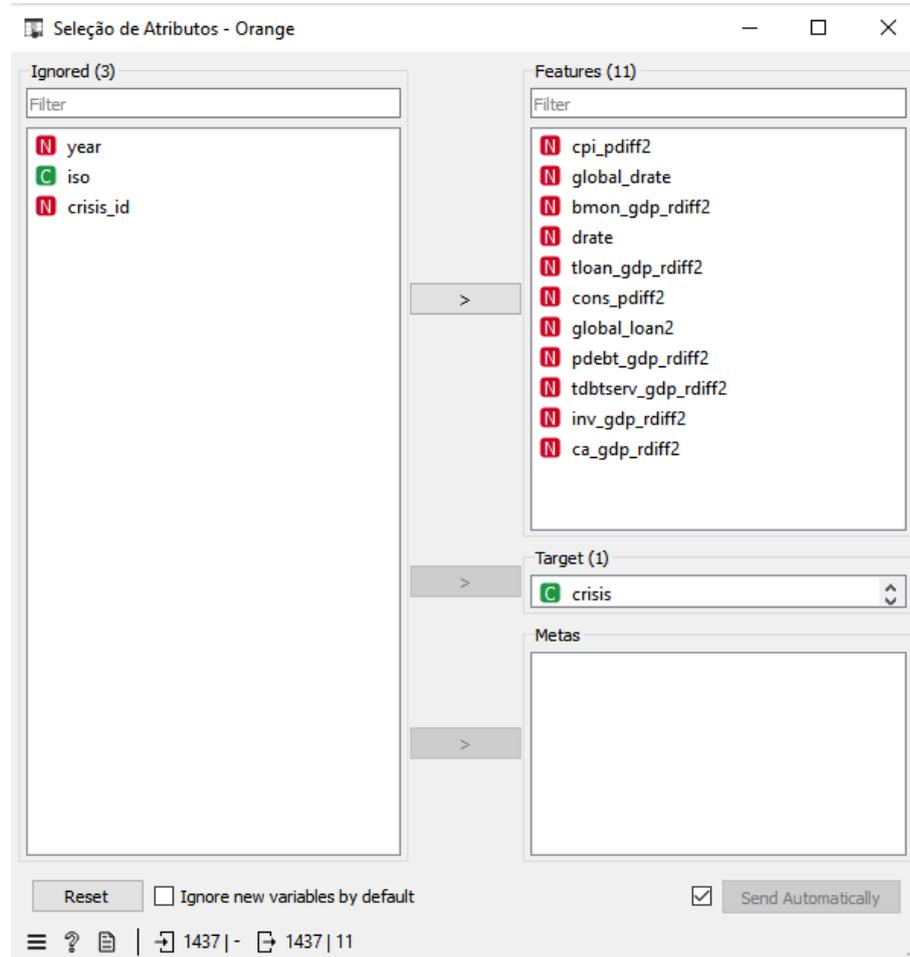
Para manter a consistência e a comparabilidade com os resultados encontrados por Bluwstein *et al.* (2020), a estratégia de *Data Cleaning* foi mantida com a definição da variável binária indicativa de crise nos dois anos que antecedem sua deflagração. Adicionalmente, o ano da crise e os quatro anos seguintes foram excluídos da análise para evitar viés de crise.

Pelo mesmo motivo, também foram excluídas todas as observações entre 1933 e 1939, relativas à Grande Depressão, bem como os períodos referentes às duas Guerras Mundiais (1914-1918 e 1939-1945). Por fim, foram excluídas as observações cujos valores dos preditores estavam ausentes.

Para realizar as referidas transformações o código utilizado no trabalho de Bluwstein *et al.* (2020), foi modificado para trabalhar com a base de dados atualizada (*JSTDatabase R6*). Esse processo gerou, a partir da base original, um conjunto de dados para o modelo contendo 11 *features* e 1437 observações (Figura 19), das quais, 102 têm um valor de classe positivo indicativo da fase de preparação para 53 crises distintas.

Contudo, como se pode observar, o conjunto de dados resultantes restou desbalanceado, devido ao baixo número de registros com indicativos de crises financeiras em relação ao total de registros. Trata-se de uma questão comum observada em problemas de classificação como a clássica detecção de fraudes, em que as ocorrências associadas aos casos positivos (instâncias de dados relacionados à classe de interesse) representam um conjunto minoritário em relação ao todo e, conseqüentemente, ao conjunto majoritário.

Figura 19 - Seleção de atributos



Fonte: Tela impressa do *software Orange Data Mining*

Esse fato também foi observado pelos autores do estudo anteriormente citado, que reportaram que a avaliação por meio da métrica AUC exibiu um alto grau de sensibilidade à baixa proporção de eventos de crise presente no conjunto de treinamento. Para garantir a comparabilidade, bem como evitar qualquer viés no modelo, os autores aplicaram técnicas de *reamostragem* (*upsampling* e *downsampling*) em todos os conjuntos de treinamento.

Técnicas baseadas em amostragem (*sampling*) são as mais difundidas quando se trata de balancear conjuntos de dados. Esses algoritmos trabalham no sentido de tornar as quantidades de amostras equivalentes entre as classes, seja através da remoção de registros na classe majoritária (*downsampling*) ou adição de novas amostras na minoritária (*upsampling*).

Para resolver essa questão, foi utilizado no caso da base desta dissertação o algoritmo *SMOTE* (*Synthetic Minority Over-sampling Technique*), cujo código está

transcrito no Apêndice E, para balancear as classes do modelo visando gerar um conjunto de treinamento equilibrado. Essa técnica foi proposta por Chawla *et al.* (2002) e é amplamente utilizada para equilibrar conjuntos de dados voltados à construção de modelos de classificação.

### 5.2.2 Engenharia de atributos

Esta etapa visa a identificação das características que determinam o comportamento geral de uma amostra, ou seja, as mais informativas, e remoção daquelas redundantes ou irrelevantes (Bonaccorso, 2017). As técnicas de seleção de atributos foram usadas para identificar as variáveis mais significativas para a previsão de crises financeiras, com o intuito de reduzir a dimensionalidade dos dados e melhorar a precisão do modelo.

De acordo com Géron (2023), a redução de dimensionalidade visa simplificar os dados sem perder muita informação e uma das estratégias para tal é a extração de atributos. O procedimento consiste em mesclar características correlacionadas, por exemplo, ao combinar quilometragem e idade de um carro em um único atributo que representa o desgaste.

A tarefa de seleção de características se baseia em análises estatísticas e em conhecimento especializado. Outro passo importante nessa fase é o dimensionamento dos atributos, que visa garantir que as características estejam em uma escala adequada para os algoritmos de aprendizado de máquina, o que pode resultar em um melhor desempenho e convergência mais rápida dos modelos.

Nessa etapa, foi utilizado novamente como referência o trabalho de Bluwstein *et al.* (2020), que realizaram uma profunda pesquisa especializada com o intuito de selecionar os atributos do modelo. Os autores destacam na literatura econômica, o crescimento do crédito como um dos preditores mais cruciais para a sinalização de crises financeiras futuras e demonstram também que a inclinação da curva de juros (diferença entre as taxas de longo e curto prazo) é frequentemente vista como um forte preditor de recessões econômicas iminentes, dentre outras características importantes que robustecem o modelo.

Por outro lado, houve uma alteração significativa da variável “stocks” entre o *release 3* do *JSTDatabase* utilizado por Bluwstein *et al.* (2020) e a versão utilizada no

presente trabalho, como consequência da mudança de abordagem para uma maior segmentação das classes de ativos e sua expressão em termos de rendimentos. Isto posto, somado ao fato de que a variável apresentou um baixo grau de importância no trabalho dos autores, optou-se por excluí-la do conjunto de *features* do presente modelo.

### 5.2.3 Treinamento do modelo

Uma vez selecionados os atributos relevantes e aplicadas as transformações relatadas nas subseções anteriores, o modelo de ML foi treinado. Nessa etapa, o algoritmo foi alimentado com um subconjunto dos dados pré-processados para aprender a prever crises financeiras a partir dos atributos identificados anteriormente.

### 5.2.4 Calibração dos hiperparâmetros

Hiperparâmetros fazem parte de um conjunto de configurações do algoritmo que são customizáveis, mas que não são aprendidas a partir dos dados (Goodfellow *et al.*, 2016). Os hiperparâmetros são responsáveis por aumentar a precisão e a performance do modelo e existem algumas técnicas para otimizar sua calibração.

Os principais hiperparâmetros do algoritmo RF estão listados no quadro a seguir, em que foi incluída uma descrição resumida do efeito de cada um sobre o funcionamento do modelo. A calibração dos hiperparâmetros frequentemente é realizada por meio de métodos de tentativa e erro ou de força bruta, o que torna o projeto de modelos de ML uma tarefa particularmente desafiadora.

Quadro 7 - Hiperparâmetros *Random Forest*

Parâmetro	Descrição
n_estimators	Número de árvores da floresta (classificador)
max_depth	Profundidade (altura) máxima da árvore
min_samples_split	Número mínimo de amostras para dividir um nó interno
min_samples_leaf	Número mínimo de amostras para estar em um nó-folha
max_features	Número de <i>features</i> a serem consideradas para buscar a melhor divisão
max_leaf_nodes	Quantidade máxima de nós-folha de uma árvore
max_samples	Número máximo de amostras para treinar cada árvore

Fonte: Elaborado pelo autor com base na documentação da classe *RandomForestClassifier*

Em contrapartida, conforme afirmam Bluwstein *et al.* (2020), RF é um algoritmo conhecido por obter bons resultados mantendo suas configurações padrão, ou seja, o investimento em otimização dos hiperparâmetros gera apenas um ganho de performance marginal. Seguindo esse raciocínio, também neste modelo apenas o valor do hiperparâmetro *n\_estimators* foi alterado para 1000 e os demais permaneceram com seu valor *default*.

### **5.2.5 Teste e validação do modelo**

Esta etapa de construção do modelo é congruente com as etapas de Demonstração e Avaliação da DSR, abordagem metodológica utilizada nesta dissertação. Nesse sentido, dada sua relevância para a presente pesquisa, o detalhamento e os resultados estão destacados a seguir em capítulo específico.

## **5.3 CONSIDERAÇÕES**

Por fim, este capítulo propôs um modelo de EWS para previsão de crises financeiras sistêmicas utilizando técnicas de ML. A pesquisa foi baseada em uma extensa revisão bibliográfica sobre modelos de previsão de crises financeiras sistêmicas e sobre técnicas de ML mais adequadas para a tarefa.

O modelo foi dividido em cinco etapas: extração e preparação dos dados; engenharia de atributos; treinamento; calibração dos hiperparâmetros; e teste e validação. O próximo capítulo materializa o modelo em uma experimentação com o intuito de demonstrar e avaliar sua eficácia e adequação ao problema apresentado nesta pesquisa por meio do alcance dos objetivos estabelecidos.

## 6 DEMONSTRAÇÃO E AVALIAÇÃO

O desempenho do *InCrAISys* foi avaliado em dois experimentos (amostragem aleatória e validação cruzada) de acordo com os as métricas apresentadas no capítulo 3. Os atributos de crises financeiras identificados pelo modelo foram analisados por meio do *framework Shapley Additive Explanations* (Lundberg & Lee, 2017) e, adicionalmente, foi utilizado o *widget Rank* do *software Orange Data Mining*, cuja explicação se encontra no Anexo A.

### 6.1 DESEMPENHO DO MODELO

No experimento de amostragem aleatória, 80% das observações foram selecionadas randomicamente para o conjunto de treinamento, enquanto os 20% restantes constituíram o conjunto de teste. Ademais, para obter resultados estáveis, a atribuição aleatória foi repetida 100 vezes.

Na validação cruzada, todas as observações incluídas foram atribuídas aleatoriamente a um dos cinco diferentes subconjuntos (*folds*). Cada subconjunto é usado uma vez como um conjunto de testes no qual o desempenho dos modelos de predição é avaliado, enquanto os restantes são usados para treinar o modelo.

A tabela a seguir apresenta os resultados obtidos em ambos os experimentos.

Tabela 3 - Desempenho do modelo

Experimento	AUC	CA	F1	Prec	Recall
Amostragem aleatória	0.990	0.953	0.953	0.953	0.953
Validação cruzada	0.990	0.952	0.952	0.952	0.952

Fonte: Amostragem aleatória e validação cruzada via *software Orange Data Mining*

Como se pode observar, o modelo apresentou alta acurácia, com a ressalva de que o conjunto de dados foi balanceado por meio da técnica SMOTE, o que contorna a principal limitação dessa métrica. Além disso, apresentou uma precisão elevada, demonstrando confiabilidade das previsões do modelo e resultados em linha com estudos similares encontrados na literatura.

As medições de *recall* também evidenciam a sensibilidade do classificador em identificar os casos de crises. Tendo em vista que os valores observados nas métricas

de precisão e *recall* foram igualmente elevados, também o *F1-score* apresentou uma alta medição, o que denota a robustez do modelo.

Por fim, a matriz de confusão também corrobora os resultados promissores do modelo, indicando sua qualidade, conforme demonstrado na tabela a seguir.

Tabela 4 - Matriz de confusão dos experimentos

	Experimento	Crise Real (%)	Não-crise Real (%)
Crise Prevista	Amostragem aleatória	94.1	5.9
	Validação cruzada	94.2	5.8
Não-crise Prevista	Amostragem aleatória	3.8	96.2
	Validação cruzada	3.3	96.7

Fonte: Dados percentuais das matrizes de confusão obtidas via *software Orange Data Mining*

## 6.2 IMPORTÂNCIA E SIGNIFICÂNCIA DOS ATRIBUTOS

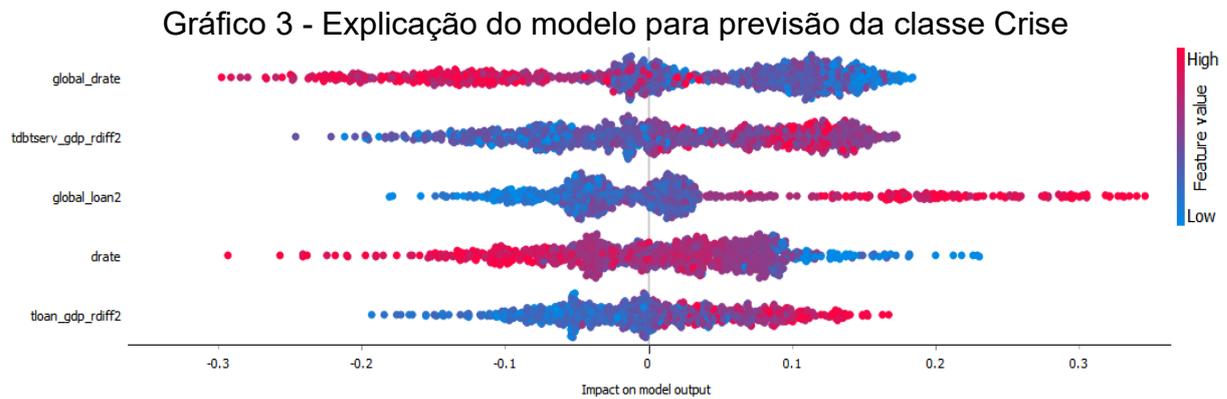
Com o intuito de explicar quais atributos têm mais peso e como contribuem para a previsão de uma classe específica, foi utilizado o *widget Explain Model* do *software Orange Data Mining*, cujos resultados estão expostos no Gráfico 3. Os pontos denotam valores *SHAP* (eixo horizontal) para o valor de cada atributo relacionado a uma determinada instância nos dados.

O valor *SHAP* é uma medida de quanto cada atributo afeta a saída do modelo, ou seja, um valor mais alto (maior desvio do centro do gráfico) denota um impacto maior na previsão da classe selecionada. Isso não significa que as variáveis realmente preveem o resultado real ou aumentam a precisão do modelo, o que é uma questão de inferência estatística.

É crucial notar que o sinal dos coeficientes não indica o sinal da associação entre os preditores e a probabilidade de crise, em vez disso, coeficientes positivos com valores de *Shapley* mais altos devem refletir um aumento na probabilidade prevista da classe positiva (crise). Valores negativos (pontos à esquerda do centro), por outro lado, têm impacto contrário na classificação para a classe em referência.

A faixa de cores é definida com base em todos os valores do atributo no conjunto de dados, com a cor vermelha representando um valor mais alto, enquanto a cor azul representa um valor mais baixo. Por fim, cabe ressaltar que os atributos são ordenados no gráfico de acordo com sua relevância para a previsão.

O intervalo segundo o qual os valores podem variar (eixo x) depende do modelo específico e do conjunto de dados analisados. Os valores de *Shapley* não têm um limite fixo ou um intervalo de variação padrão, pois são calculados com base na contribuição marginal de cada atributo para a previsão do modelo.



Pela leitura do gráfico, depreende-se que os atributos que mais influenciam na previsão de instâncias de crise, em ordem de importância, são: inclinação da curva de juros global (*global\_drate*); taxa de serviço da dívida (*tdbtserv\_gdp\_rdiff2*); crédito global (*global\_loan2*); inclinação da curva de juros (*drate*); e crédito (*tloan\_gdp\_rdiff2*). Em relação ao crédito e taxa de juros (tanto global, como local), o modelo se apresenta bem alinhado ao trabalho de Bluwstein *et al.* (2020), entretanto, a taxa de serviço da dívida parece surgir como um novo fator de influência na previsão de crises.

Por outro lado, os mesmos autores ao segmentar o período coberto pela base de dados, observam que a taxa de serviço da dívida foi um dos preditores-chave para as crises dos anos 90. Adicionalmente, a referida taxa é calculada em função da taxa de juros de longo prazo, assim como a inclinação da curva de juros, o que pode indicar que os atributos estão correlacionados, embora seja necessária uma análise estatística mais aprofundada para embasar cientificamente tal inferência.

Conquanto a distribuição dos pontos com valores mais altos ou baixos não seja absolutamente uniforme em cada lado do gráfico, observa-se que valores mais baixos na inclinação da curva de juros global tendem a aumentar a probabilidade de prever uma crise financeira. Em contraste, é mais provável que uma previsão de crise seja positiva quando há valores mais elevados na taxa de serviço da dívida e no crédito global.

Entretanto, a inferência pode não ser inteiramente apoiada pelos dados do gráfico, possivelmente devido à presença de não linearidades e interações entre as características, conforme mencionado no estudo de Bluwstein *et al.* (2020). De acordo com os autores, existe uma não linearidade significativa no crescimento do crédito global, em que apenas valores muito altos influenciam a previsão de crise.

Esse achado sugere que, até certo ponto, aumentos no crédito global não têm um efeito substancial na previsão, contudo, após ultrapassar um certo limiar, o impacto torna-se mais direto. Bluwstein *et al.* (2020) também afirmam que uma curva de rendimento global plana ou invertida, quando combinada com um forte crescimento de crédito doméstico, pode indicar um risco significativo de crise.

Modelos de ML são capazes de detectar essas relações complexas e não lineares entre as variáveis, que não são facilmente interpretáveis em análises univariadas ou gráficos simples. Isto pode explicar por que o gráfico de valores de *Shapley* não mostra uma tendência linear, que não pode ser simplificada ou reduzida a uma inclinação de aumento ou diminuição relacionada a um atributo que influencia a previsão.

Portanto, embora o gráfico de valores *SHAP* forneça *insights* valiosos sobre a importância e o impacto das características individuais, é crucial considerar a importância e a complexidade das interações entre as variáveis. As não linearidades, as interações e o contexto do domínio são essenciais para uma compreensão completa de como as características afetam a previsão de um modelo de ML.

A propósito, conforme exposto na Tabela 5, o *widget Rank* ratifica a significância dos mesmos atributos destacados pelo *framework SHAP*, quais sejam: inclinação da curva de juros global; crédito; inclinação da curva de juro; taxa de serviço da dívida; e crédito global. Com alguma diferença na ordem de importância entre os métodos, ambos apontam exatamente os mesmos *top 5* fatores de influência na previsão de crises.

Tabela 5 - Top 5 fatores de influência na previsão de crises.

#	Feature	Info. gain	Gain ratio	Gini	ANOVA	$\chi^2$	ReliefF	FCBF
1	global_drate	0.166	0.083	0.105	597.691	383.301	0.029	0.124
2	tloan_gdp_rdiff2	0.097	0.049	0.065	337.176	283.418	0.021	0.069
3	drate	0.085	0.042	0.057	286.410	234.873	0.026	0.000
4	tdbtserv_gdp_rdiff2	0.071	0.035	0.047	240.783	181.983	0.014	0.000
5	global_loan2	0.068	0.034	0.046	374.128	139.657	0.021	0.000

Fonte: Dados obtidos por meio do *widget Rank* do software *Orange Data Mining*

Importa destacar que o *widget Rank* utiliza medidas estatísticas (Anexo A) diretamente sobre os dados sem levar em conta a técnica de ML utilizada para calcular a correlação dos atributos com a variável alvo indicativa de crise. Nesse sentido, pode-se observar que, por meio de ferramentas diversas aplicadas em fases diferentes do experimento, chegou-se ao mesmo conjunto de atributos-chave para a previsão de crises.

### 6.3 ADEQUAÇÃO DO MODELO AO PROBLEMA

De acordo com os procedimentos metodológicos que governam este trabalho, há que se comprovar o nível de efetividade do artefato como solução para o problema. Essa atividade envolve a comparação dos objetivos da solução com os resultados reais observados do uso do artefato na demonstração.

Nesse sentido, conforme relatado nas subseções anteriores, as métricas estabelecidas apontam no sentido de que o modelo proposto (*InCrAISys*) foi efetivo em identificar padrões e índices (atributos) capazes prever antecipadamente a ocorrência de crises financeiras por meio de técnicas de *Machine Learning*. A demonstração do modelo por meio dos experimentos de amostragem aleatória e validação cruzada também revela que o modelo alcançou os objetivos estabelecidos.

Os atributos mais influentes – inclinação da curva de juros (global e local); crédito (global e local); e taxa de serviço da dívida – sem perder de vista os 6 demais, apresentam potencial para sinalizar precocemente a ocorrência de crises financeiras. O algoritmo *Random Forest* também se mostrou eficaz em detectar padrões e relações não-lineares nos dados do modelo e, com o auxílio de outras técnicas utilizadas, como o *framework SMOTE*, também foi capaz de lidar com o conjunto limitado de eventos de crise financeira.

Finalmente, a base de dados utilizada (*JSTDatabase*), com as modificações aplicadas, se mostrou completa e confiável para treinar e testar o modelo. Isto posto, é possível considerar que o modelo foi efetivo e pode servir de base para a construção de Sistemas de Alerta Precoce para previsão de crises financeiras visando apoiar a tomada de decisão relacionada às políticas macroprudenciais com base em evidências.

## 7 CONCLUSÃO

Esta dissertação se propôs a investigar como apoiar a sinalização precoce de possíveis crises financeiras sistêmicas. A DSR foi identificada como metodologia adequada para abordar tal problema, tendo em vista que provê tratamento metodológico rigoroso e apropriado, que fornece validade científica aos resultados da pesquisa, porém com o enfoque de construir artefatos com aplicação prática.

O processo da metodologia é estruturado a partir de seis atividades sequenciais e iterativas, quais sejam: identificação do problema e motivação; definição dos objetivos para uma solução; *design* e desenvolvimento; demonstração; avaliação; e comunicação. No contexto deste trabalho, partiu-se da revisão da literatura relacionada a crises financeiras e seus indicadores, bem como do uso de técnicas de ML em Sistemas de Alerta Precoce para crises financeiras, seguida da definição da problemática e estabelecimento da questão de pesquisa.

Com base no conhecimento do estado do problema e na importância de sua solução, foi estabelecido o objetivo de propor um modelo de EWS para crises financeiras a partir da extração de conhecimento de bases de dados por meio de técnicas de ML. O *design* da solução partiu da identificação dos componentes (base de dados, atributos e técnica de ML), e a construção seguiu as seguintes etapas: extração e preparação dos dados; seleção e engenharia de atributos; treinamento do modelo; calibração dos hiperparâmetros; e teste e validação do modelo.

A demonstração como prova de uso do artefato foi materializada por meio da implementação do modelo *InCrAISys* utilizando a plataforma *Orange* e a classe *RandomForestClassifier* da biblioteca *sklearn* do *Python* sobre os dados modificados do *JSTDatabase*. A validação do modelo se deu de forma empírica e por meio de métricas específicas utilizadas para avaliar a eficácia de modelos de ML, quais sejam: AUC, acurácia, precisão, *recall* e *F1-score*.

A pesquisa teve êxito em relação ao objetivo geral, na medida em que o modelo de sistema de alerta precoce proposto alcançou alta acurácia e precisão segundo todas as métricas de eficácia aplicadas. Ademais, cada objetivo específico foi cumprido, a começar por identificar um conjunto confiável de padrões comuns às crises financeiras sistêmicas, que apresentem potencial para sinalizar sua possibilidade de ocorrência precocemente.

O modelo identificou o crescimento do crédito, a curva de juros e a taxa de serviço da dívida como os atributos de maior impacto na previsão de crises, o que está em linha tanto com a literatura científica quanto a prática dos órgãos do sistema financeiro global. Outros atributos, como consumo, investimento e dívida pública, também contribuem para o modelo, porém com menor peso, de acordo com os métodos aplicados para apurar sua importância e significância.

Para entender o racional econômico por trás da escolha de cada um dos atributos, recorreu-se à literatura especializada, tendo em vista que este trabalho não tem a pretensão de discutir o tema em profundidade dado o enfoque do programa em que está circunscrito. Entretanto, há que se ressaltar que o conjunto dos atributos foi testado extensivamente pelos autores utilizados como *benchmark* em associação com uma série de técnicas de ML e demonstrou resultados bastante promissores, o que foi corroborado no presente estudo.

O objetivo específico de obter base de dados financeira que contemplasse as variáveis previamente identificadas foi atingido por meio da identificação e transformação do *JSTDatabase*. A base original contempla um conjunto abrangente de dados macroeconômicos e financeiros aderentes ao problema desta pesquisa, que passou por um processo de limpeza, seleção de variáveis e normalização dos dados para alimentar o modelo proposto.

O trabalho também foi efetivo em selecionar técnicas de ML capazes de extrair conhecimento de padrões e relações não-lineares em dados financeiros. O algoritmo *Random Forest*, com o auxílio de outras técnicas utilizadas, como o *framework SMOTE* para balancear os dados, foi eficaz em lidar com o conjunto limitado de eventos de crise financeira e identificar sinais capazes de antecipar sua ocorrência.

O modelo trouxe ainda um benefício adicional que colabora para sua adoção no sentido de aliviar consideravelmente a reputação de “caixa-preta” dada às técnicas de *Machine Learning*. Os valores de *Shapley* forneceram parâmetros relevantes sobre quais atributos influenciaram nos resultados de determinada previsão, o que contribui para a discussão sobre a interpretabilidade dos modelos de ML, um desafio crucial para sua adoção em contextos de tomada de decisão.

Isso ocorre porque os valores de *Shapley* permitem quantificar o impacto individual de cada atributo na previsão do modelo, o que adiciona transparência ao raciocínio por trás das decisões tomadas pelo algoritmo. Entretanto, é importante considerar as interações entre as variáveis, tendo em vista que modelos de ML são capazes de identificar essas relações complexas e não lineares, não detectáveis diretamente por outros meios.

Vale destacar que o desenvolvimento de um sistema de alerta precoce para crises financeiras é uma tarefa complexa que requer uma consideração cuidadosa de muitos fatores. Portanto, a principal limitação é que toda solução no campo econômico parte de uma equação reduzida com a exclusão de algumas variáveis, o que é potencializado no contexto de ML, em que uma das principais técnicas da engenharia de atributos para a redução da complexidade na construção dos modelos é exatamente a redução da dimensionalidade.

Ademais, o modelo desenvolvido é tão bom quanto a base de dados, os atributos e as técnicas de ML aplicadas, que representam as escolhas deste autor, em que pese estejam baseadas nas melhores práticas e achados da literatura. Adicionalmente, é importante ter em mente que as crises financeiras são eventos raros, o que também pode impactar o desempenho do modelo e tornar sua avaliação e interpretação difícil na prática.

Nesse sentido, são necessários mais testes, inclusive com dados de outras fontes, bem como alguns refinamentos no modelo para garantir seu desempenho em situações reais de uso. Possíveis trabalhos futuros podem ser desenvolvidos com foco em avaliar a precisão e robustez do modelo proposto nesse contexto, bem como na construção de novos conjuntos de dados e alimentação do modelo para avaliar sua eficácia.

Uma extensão natural do presente estudo é a aplicação do modelo ao contexto nacional, para isso, seria necessário construir uma base de dados com indicadores macroeconômicos e financeiros relevantes para a economia brasileira, abrangendo um período estatisticamente significativo. Ademais, a análise da interação entre variáveis políticas e econômico-financeiras poderia fornecer uma visão ainda mais abrangente dos fatores que desencadeiam crises financeiras e contribuir para o aprimoramento da capacidade preditiva do modelo.

Nessa linha, vale ressaltar que o presente estudo se concentrou em variáveis macroeconômicas e financeiras para a previsão de crises financeiras, reconhecendo, contudo, a importância de fatores políticos como potenciais indicadores de alerta precoce. Estudos futuros poderiam explorar a inclusão de variáveis políticas e seu impacto na probabilidade de ocorrência de crises financeiras.

Esse mesmo raciocínio pode ser aplicado a outros tipos de dados, incluindo os textuais, como postagens em redes sociais, o que se torna cada vez mais viável com a popularização dos LLMs, que são eficazes em extrair significado e conhecimento a partir de dados não estruturados. Novas pesquisas podem ainda se concentrar na melhoria da interpretabilidade do modelo e na incorporação de recursos adicionais para aumentar seu poder preditivo.

A matriz de confusão revelou um baixo índice de crises financeiras que não foram previstas pelo modelo (falsos negativos ou erros tipo II), entretanto, em um contexto de baixa tolerância a riscos, a não detecção de uma crise pode não ser um resultado apropriado. Seguindo esse raciocínio, trabalhos futuros poderiam explorar a possibilidade de aumentar a sensibilidade do modelo por meio da calibração dos hiperparâmetros ou ainda da aplicação de outras técnicas de ML.

Finalmente, esta pesquisa avança nos estudos de Engenharia do Conhecimento nas organizações ao explorar a aplicação das técnicas de ML para a extração de conhecimento em um domínio complexo e relevante: a previsão de crises financeiras sistêmicas. Adicionalmente, o trabalho demonstra o potencial dessas técnicas para a descoberta de conhecimento e sua estruturação para a construção de soluções com aplicação prática visando fornecer subsídios para tomadas de decisões mais fundamentadas e assertivas.

## REFERÊNCIAS

- AIKMAN, D.; KILEY, M.; LEE, S. J.; PALUMBO, M. G. *et al.* Mapping heat in the U.S. financial system. **Journal of Banking and Finance**, 81, p. 36-64, 2017. DOI: 10.1016/j.jbankfin.2017.04.013.
- ALESSI, L. *et al.* **Comparing Different Early Warning Systems**: Results from a Horse Race Competition Among Members of the Macro-Prudential Research Network. MPRA Paper, University Library of Munich, Germany, n. 62194, fev. 2015. DOI: 10.2139/ssrn.2566165.
- ALESSI, L.; DETKEN, C. Identifying excessive credit growth and leverage. **Journal of Financial Stability**, v. 35, p. 215-225, abr. 2018. DOI: 10.1016/j.jfs.2017.06.005.
- ALPAYDIN, E. **Introduction to Machine Learning** (4th ed.). Cambridge: MIT Press, 2020.
- ALVAREZ, G. M. **Análise de agrupamentos e mineração de opinião como suporte à gestão de ideias**. 2018. Dissertação (Mestrado em Engenharia e Gestão do Conhecimento) - Universidade Federal de Santa Catarina, Florianópolis, 2018.
- APOTEKER, T.; BARTHÉLÉMY, S. Predicting financial crises in emerging markets using a composite non-parametric model. **Emerging Markets Review**, v. 6, n. 4, p. 363-375, 2005. DOI: 10.1016/j.ememar.2005.09.002.
- ARKSEY, H.; O'MALLEY, L. Scoping studies: Towards a methodological framework. **International Journal of Social Research Methodology**, v. 8, n. 1, p. 19-32, 2005. DOI: 10.1080/1364557032000119616.
- BAJARI, P.; NEKIPELOV, D.; RYAN, S. P.; YANG, M. Machine learning methods for demand estimation. **American Economic Review**, v. 105, n. 5, p. 481-485, 2015. DOI: 10.1257/aer.p20151021.
- BANK FOR INTERNATIONAL SETTLEMENTS – BIS. Recent innovations in international banking (Cross Report), Committee on the Global Financial System, **CGFS Papers**, n. 1, 1986. Disponível em: <https://www.bis.org/publ/ecsc01.htm>. Acesso em: 03 mar 2022.
- BARIŞIK, S.; TAY, A. An analysis of financial crisis by early warning systems approach: The case of transition economies and emerging markets (1994-2006 Period Panel Logit Model). **International Journal of Economic Perspectives**, v. 4, n. 2, p. 403-426, 2010.
- BARWELL, R. **Macroprudential Policy**: Taming the Wild Gyration of Credit Flows, Debt Stocks and Asset Prices. Londres: Palgrave Macmillan, 2013.
- BERG, A.; BORENSZTEIN, E.; MILESI-FERRETTI, G.M.; PATTILLO, C. Anticipating Balance of Payments Crises: The Role of Early Warning Systems. **International Monetary Fund Occasional Paper**, n. 186, 1999.

BEUTEL, J.; LIST, S.; VON SCHWEINITZ, G. An evaluation of early warning models for systemic banking crises: Does machine learning improve predictions? **Bundesbank Discussion Paper**, Frankfurt, n. 48, 2018.

BLANCK, H. **Capital de risco e startups**: modelo de suporte na tomada de decisão com aprendizado de máquina. 2020. Dissertação (Mestrado em Engenharia e Gestão do Conhecimento) - Universidade Federal de Santa Catarina, Florianópolis, 2020.

BLUNDELL-WIGNALL, A.; ROULET, C. Macro-prudential policy, bank systemic risk and capital controls. **OECD Journal: Financial Market Trends**, v. 2013, n. 2, p. 7-28, 2014. DOI: 10.1787/fmt-2013-5jzb2rhkhks4.

BLUWSTEIN, K. *et al.* Credit growth, the yield curve and financial crisis prediction: evidence from a machine learning approach. **Bank of England working papers**, n. 848, jan 2020.

BONACCORSO, G. **Machine Learning Algorithms**: A reference guide to popular algorithms for data science and machine learning. Birmingham: Packt Publishing Ltd, 2017.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001. DOI: 10.1023/A:1010933404324.

BROWN, T. B. *et al.* Language Models are Few-Shot Learners. **Proceedings of the Thirty-fourth Annual Conference on Neural Information Processing Systems (NeurIPS 2020)**, p. 1877-1901, dec. 2020. DOI: 10.48550/arXiv.2005.14165.

BUNDA, I.; CA' ZORZI, M. Signals from housing and lending booms. **Emerging Markets Review**, v. 11, n. 1, p. 1-20, 2010. DOI: 10.1016/j.ememar.2009.09.003.

BUSSIERE, M.; FRATZSCHER, M. Towards a new early warning system of financial crises. **Journal of International Money and Finance**, v. 25, n. 6, p. 953-973, 2006. DOI: 10.1016/j.jimonfin.2006.07.007.

CECI, F. **Um modelo baseado em casos e ontologia para apoio à tarefa intensiva em conhecimento de classificação com foco na análise de sentimentos**. 2015. Tese (Doutorado em Engenharia e Gestão do Conhecimento) - Universidade Federal de Santa Catarina, Florianópolis, 2015.

CHAMBERS, D. *et al.* Maximizing the impact of systematic reviews in health care decision making: a systematic scoping review of knowledge-translation resources. **Milbank Q.**, v. 89, n. 1, p. 131-156, 2011. DOI: 10.1111/j.1468-0009.2011.00622.x.

CHAWLA, N. V.; BOWYER, K. W.; HALL, L. O.; KEGELMEYER, W. P. SMOTE: Synthetic Minority Over-sampling Technique. **Journal of Artificial Intelligence Research**, v. 16(1), p. 321-357, jun. 2002. DOI: 10.48550/arXiv.1106.1813.

CHRISTENSEN, I.; LI, F. Predicting financial stress events: A signal extraction approach. **Journal of Financial Stability**, v. 14, p. 54-65, out. 2014. DOI: 10.1016/j.jfs.2014.08.005.

DAVENPORT, T.; PRUSAK, L. **Working with Knowledge**: how organizations manage what they know. Boston: Harvard Business School Press, 1998.

DAVIES, P. The State of Evidence-Based Policy Evaluation and its Role in Policy Formation. **National Institute Economic Review**, v. 219, n. 1, p. R41-R52, 2012. DOI: 10.1177/002795011221900105.

DEISENROTH, M. P.; FAISAL, A. A.; ONG, C. S. **Mathematics for Machine Learning**. Cambridge: Cambridge University Press, 2020.

DEMIRGÜÇ-KUNT, A.; DETRAGIACHE, E. The determinants of banking crises in developing and developed countries. **IMF Staff Papers**, v. 45, n. 1, p. 81-109, 1998.

DEMŠAR, J.; ZUPAN, B. Orange: Data mining fruitful and fun - A historical perspective. **Informatica** (Slovenia), v. 37, p. 55-60, 2013.

DRESCH, A.; LACERDA, D. P.; ANTUNES, J. A. V. **Design Science Research**: A method for science and technology advancement. Cham: Springer, 2015.

EDISON, H. J. Do indicators of financial crises work? An evaluation of an early warning system. **International Journal of Finance and Economics**, v. 8, n. 1, p. 11-53, 2003. DOI: 10.1002/ijfe.197.

EICHENGREEN, B.; PORTES, R. The Anatomy of Financial Crises. **NBER Working Paper**, n. 2126, 1987.

EICHENGREEN, B.; ROSE, A.; WYPLOSZ, C. Exchange Market Mayhem: The Antecedents and Aftermath of Speculative Attacks. **Economic Policy**, v. 21, p. 249-312, out. 1995. DOI: 10.2307/1344591.

FAGUNDES, V. B. **Proposta de uso de Engenharia do Conhecimento para revisão sistemática**. 2018. Dissertação (Mestrado em Engenharia e Gestão do Conhecimento) - Universidade Federal de Santa Catarina, Florianópolis, 2018.

FARACO, F.M. **Modelo de conhecimento baseado em tópicos de acórdãos para suporte à análise de petições iniciais**. 2020. Dissertação (Mestrado em Engenharia e Gestão do Conhecimento) - Universidade Federal de Santa Catarina, Florianópolis, 2020.

FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From Data Mining to Knowledge Discovery in Databases. **AI Magazine**, v. 17, n. 3, p. 37-54, 1996. DOI: 10.1609/aimag.v17i3.1230.

FINANCIAL STABILITY BOARD – FSB; INTERNATIONAL MONETARY FUND – IMF; BANK FOR INTERNATIONAL SETTLEMENTS – IES. Macroprudential Policy Tools and Frameworks, **Progress Report to G20**, 2011.

FIORAMANTI, M. Predicting sovereign debt crises using artificial neural networks: A comparative approach. **Journal of Financial Stability**, v. 4, n. 2, p. 149-164, 2008. DOI: 10.1016/j.jfs.2008.01.001.

FOULIARD, J.; HOWELL, M.; REY, H. Answering the Queen: Machine Learning and Financial Crises. **BIS Working Papers**, n. 926, 2021.

FRANKEL, J.; ROSE, A. Currency crashes in emerging markets: an empirical treatment. **Journal of International Economics**, v. 41 (3/4), p. 351-366, 1996. DOI: 10.1016/S0022-1996(96)01441-9.

FRANKEL, J.; SARAVELOS, G. Can leading indicators assess country vulnerability? Evidence from the 2008-09 global financial crisis. **Journal of International Economics**, v. 87, n. 2, p. 216-231, 2012. DOI: 10.1016/j.jinteco.2011.12.009.

FREUND, Y.; SCHAPIRE R. E. Experiments with a New Boosting Algorithm. **Proceedings of the 13th International Conference on Machine Learning (ICML'96)**, p. 148-156, Bari, Italy, jul. 1996.

GALÁN, J. E.; MENCÍA, J. Model-based indicators for the identification of cyclical systemic risk. **Empirical Economics**, v. 61, n. 6, p. 3179-3211, 2021. DOI: 10.1007/s00181-020-01993-2.

GAROUSI, V.; FELDERER, M.; MÄNTYLÄ, V. Guidelines for including grey literature and conducting multivocal literature reviews in software engineering. **Information and Software Technology**, v. 106, n. 19, p. 101-121, 2019. DOI: 10.1016/j.infsof.2018.09.006.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. (3rd ed.) Sebastopol: O'Reilly Media, Inc., 2023.

GOLDSTEIN, M.; KAMINSKY, G REINHART, C. **Assessing financial vulnerability: An early warning system for emerging markets**. Washington, DC: Institute for International Economics, 2000.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Cambridge: MIT Press, 2016.

GRIMSHAW, J. **A guide to knowledge synthesis: a knowledge synthesis chapter**. Ottawa: Canadian Institutes of Health Research, 2010. Disponível em: <https://cihr-irsc.gc.ca/e/41382.html>. Acesso em: 13 dez. 2021.

GURU, A. Early warning system of finance stress for India. **International Review of Applied Economics**, v. 30, n. 3, p. 273-300, 2016. DOI: 10.1080/02692171.2015.1102206.

HAND, D.; MANNILA, H.; SMYTH, P. **Principles of Data Mining**. Cambridge: MIT Press, 2001.

HELLWIG, K. P. Predicting Fiscal Crises: A Machine Learning Approach. **IMF Working Papers**, v. 2021, n. 150, maio 2021.

HERWATZ, H.; KHOLODILIN, K. A. In-sample and out-of-sample prediction of stock market bubbles: Cross-sectional evidence. **Journal of Forecasting**, v. 33, p. 15-31, 2014. DOI: 10.1002/for.2269.

HEVNER, A. R.; MARCH, S. T.; PARK, J.; RAM S. Design science in information systems research. **MIS Quarterly**, v. 28, n. 1, p. 75-105, 2004. DOI: 10.2307/25148625.

HOLOPAINEN, M.; SARLIN, P. Toward Robust Early-Warning Models: A Horse Race, Ensembles and Model Uncertainty. **Working Paper Series**, European Central Bank, n. 1900, maio 2016.

HOLOPAINEN, M.; SARLIN, P. Toward Robust Early-Warning Models: A Horse Race, Ensembles and Model Uncertainty. **Quantitative Finance**, v. 17, issue 12, p. 1933-1963, 2017. DOI: 10.1080/14697688.2017.1357972.

HOSSEINZADEH, M. et al. A multiple multilayer perceptron neural network with an adaptive learning algorithm for thyroid disease diagnosis in the internet of medical things. **The Journal of Supercomputing**, v. 77, p. 3616-3637, 2021. DOI: /10.1007/s11227-020-03404-w.

INTERNATIONAL MONETARY FUND - IMF. How to Assess Country Risk: The Vulnerability Exercise Approach Using Machine Learning, **IMF Technical Notes and Manuals**, v. 2021, n. 003, maio 2021.

JARMULSKA, B. Random Forest Versus Logit Models: Which Offers Better Early Warning of Fiscal Stress? **Working Paper Series**, European Central Bank, n. 2408, maio 2020.

JEMOVIĆ, M.; MARINKOVIĆ, S. Determinants of financial crises-An early warning system based on panel logit regression. **International Journal of Finance and Economics**, v. 26, n. 1, p. 103-117, 2021. DOI: 10.1002/ijfe.1779.

JOLLIFFE, I.T.; CADIMA J. Principal component analysis: a review and recent developments. **Phil. Trans. R. Soc.**, v. 374, Issue 2065, 2016. DOI: 0.1098/rsta.2015.0202.

JORDÀ, O.; SCHULARICK, M.; TAYLOR, A.M. Macrofinancial History and the New Business Cycle Facts. **NBER Macroeconomics Annual 2016**, v. 31. Chicago: University of Chicago Press, 2017.

JORDÀ, O.; SCHULARICK, M.; TAYLOR, A.M. The Effects of Quasi-random Monetary Experiments. **Journal of Monetary Economics**, v. 112, p. 22-40, 2020. DOI: 10.1016/j.jmoneco.2019.01.021.

JOY, M.; RUSNÁK, M.; ŠMÍDKOVÁ, K.; VAŠÍČEK, B. Banking and Currency Crises: Differential Diagnostics for Developed Countries. **International Journal of Finance and Economics**, v. 22, n. 1, p. 44-67, 2017. DOI: 10.1002/ijfe.1570.

KAMIN, S. B.; SCHINDLER, J.; SAMUEL, S. The contribution of domestic and external factors to emerging market currency crises: An early warning systems approach. **International Journal of Finance and Economics**, v. 12, n. 3, p. 317-336, 2007. DOI: 10.1002/ijfe.314.

KAMINSKY, G. L. Currency and Banking Crises: The Early Warnings of Distress. **Board of Governors of the Federal Reserve System, International Finance Discussion Paper**, n. 629, 1998.

KAMINSKY, G. L. Varieties of currency crises. **NBER Working Paper**, n. 10193, 2003.

KAMINSKY, G. L.; LIZONDO, S.; REINHART, C. Leading Indicators of Currency Crisis. **IMF Staff Papers**, v. 45, n. 1, p. 1-48, 1998.

KAMINSKY, G. L.; REINHART, C. M. The twin crises: The causes of banking and balance-of-payments problems. **American Economic Review**, v. 89, n. 3, p. 473-500, 1999. DOI: 10.1257/aer.89.3.473.

KASTER, G. B. **Framework Conceitual Baseado em Aprendizagem de Máquina Supervisionada para Concepção de Sistemas Judiciais de Agentes Inteligentes**. 2021. Dissertação (Mestrado em Engenharia e Gestão do Conhecimento) - Universidade Federal de Santa Catarina, Florianópolis, 2021.

KHANKEH, H. R.; HOSSEINI, S. H.; FARROKHI, M.; HOSSEINI, M.A.; AMANAT, N. Early warning system models and components in emergency and disaster: a systematic literature review protocol. **Systematic Reviews**, v. 8, p. 315, 2019. DOI: 10.1186/s13643-019-1211-5.

KITCHENHAM, B. A.; DYBA, T.; JORGENSEN, M. Evidence-based Software Engineering. **Proceedings of 26th International Conference on Software Engineering**, p. 273-281, maio 2004. DOI: 10.1109/ICSE.2004.1317449.

KITCHENHAM, B.; CHARTERS, S. **Guidelines for Performing Systematic Literature Reviews in Software Engineering**, Technical Report EBSE, Keele University and Durham University Joint Report, version 2.3, 2007.

KLOPOTAN, I.; ZOROJA, J.; MEŠKO, M. Early warning system in business, finance, and economics: Bibliometric and topic analysis. **International Journal of Engineering Business Management**. Vol. 10: 1-12, 2018. DOI: 10.1177/1847979018797013.

KUHN, M.; JOHNSON, K. **Applied Predictive Modeling**. Nova Iorque: Springer, 2018.

LACERDA, D. P. *et al.* Design Science Research: método de pesquisa para a engenharia de produção. **Gestão & Produção**, v. 20, n. 4, p. 741-761, 2013. DOI: 10.1590/S0104-530X2013005000014.

LAEVEN, L.; VALENCIA, F. Systemic Banking Crises Database. **IMF Economic Review**, v. 61, n. 2, p.225-270, 2013. DOI: 10.1057/imfer.2013.12.

LAEVEN, L.; VALENCIA F. Systemic Banking Crises Revisited. **IMF Working Papers**, v. 2018, n. 206, set. 2018.

LIPTON, Z. The Mythos of Model Interpretability: In machine learning, the concept of interpretability is both important and slippery. **Queue**. v. 16, Issue 3, maio-jun. 2018. DOI: 10.1145/3236386.3241340.

LIU, L.; CHEN, C.; WANG, B. Predicting financial crises with machine learning methods. **Journal of Forecasting**, 2021. DOI: 10.1002/for.2840.

LO DUCA, M. L.; PELTONEN, T. A. Assessing systemic risks and predicting systemic events. **Journal of Banking and Finance**, v. 37, n. 7, p. 2183-2195, 2013. DOI: 10.1016/j.jbankfin.2012.06.010.

LUNDBERG, S.M.; LEE, S. A Unified Approach to Interpreting Model Predictions. **Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017)**, p. 4765-4774, CA, USA, 2017. DOI: 10.48550/arXiv.1705.07874.

MANASSE, P.; SAVONA, R.; VEZZOLI, M. Danger Zones for Banking Crises in Emerging Markets. **International Journal of Finance and Economics**, v. 21, n. 4, p. 360-381, 2016. DOI: 10.1002/ijfe.1550.

MARCH, S. T.; STOREY, V. C. Design science in the information systems discipline: An introduction to the special issue on design science research. **MIS Quarterly**, v. 32, n. 4, p. 725-730, 2008. DOI: 10.2307/25148869.

MORGAN, M.S.; MORRISON, M. **Models as Mediators: Perspectives on Natural and Social Science**. Cambridge: Cambridge University Press, 1999.

NAZÁRIO, D. C; DANTAS, M. A. R.; TODESCO, J. L. Knowledge Engineering: Survey of Methodologies, Techniques and Tools. **IEEE Latin America Transactions**, v. 12, n. 8, p. 1553-1559, dez. 2014. DOI: 10.1109/TLA.2014.7014527.

NEYMAN, J.; PEARSON, E. S. On the Problem of the Most Efficient Tests of Statistical Hypotheses. **Philosophical Transactions of the Royal Society of London**. Series A, Containing Papers of a Mathematical or Physical Character, v. 231, n. 694-706, p. 289-337, 1933.

NIK, P. A.; JUSOH, M.; SHAARI, A. H.; SARMDI, T. Predicting the probability of financial crisis in emerging countries using an early warning system: Artificial neural network. **Journal of Economic Cooperation and Development**, v. 37, n. 1, p. 25-40, 2016.

ORGANISATION FOR ECONOMIC CO-OPERATION AND DEVELOPMENT - OECD. **Embracing innovation in government - Global trends 2017**. Paris: OECD Publishing, fev. 2017.

PEFFERS, K.; TUUNANEN, T.; ROTHENBERGER, M. A.; CHATTERJEE, S. A. Design Science Research Methodology for Information Systems Research. **Journal of Management Information Systems**, v. 24, n. 3, p. 45-77, 2007. DOI: 10.2753/MIS0742-1222240302.

PROCEEDINGS of the **Third International Conference on Grey Literature – GL'97**. 13-14, 1997, Luxemburg, nov. 1998.

PUGLIA, M.; TUCKER, A. Machine Learning, the Treasury Yield Curve and Recession Forecasting. **Finance and Economics Discussion Series**, Board of Governors of the Federal Reserve System (U.S.), n. 38, maio 2020.

REINHART, C. M.; ROGOFF, K. S. **This time is different: Eight centuries of financial folly**. Princeton: Princeton University Press, 2009.

SAMITAS, A.; KAMPOURIS, E.; KENOURGIOS, D. Machine learning as an early warning system to predict financial crisis. **International Review of Financial Analysis**, v. 71, 2020. DOI: 10.1016/j.irfa.2020.101507.

SCHREIBER, G.; *et al.* **Knowledge engineering and management: the CommonKADS methodology**. Cambridge: MIT Press, 2000.

SHAPLEY, L. A Value for n-Person Games. In: KUHN, H.; TUCKER, A.; Eds. **Contributions to the Theory of Games II**. p. 307-317, Princeton: Princeton University Press, 1953.

SHI, J.; GAO, Y. A study on KLR financial crisis early-warning model. **Frontiers of Economics in China**, v. 5, n. 2, p. 254-275, 2010. DOI: 10.1007/s11459-010-00134.

SILVA, S. N. **Modelo de Engenharia do Conhecimento para a evasão no ensino superior**. 2021. Dissertação (Mestrado em Engenharia e Gestão do Conhecimento) - Universidade Federal de Santa Catarina, Florianópolis, 2021.

SUSS, J.; TREITEL, H. Predicting bank distress in the UK with machine learning. **Bank of England working papers**, n. 831, 2019.

TANAKA, K.; KINKYO, T.; HAMORI, S. Random Forests-Based Early Warning System for Bank Failures. **Economics Letters**, v. 148, p. 118-121, 2016. DOI: 10.1016/j.econlet.2016.09.024.

TRICCO, A. C. *et al.* PRISMA extension for scoping reviews (PRISMA-ScR): checklist and explanation. **Annals of Internal Medicine**, v. 169, n. 7, p. 467-473, 2018. DOI: 10.7326/M18-0850.

VAN AKEN, J.; CHANDRASEKARAN, A.; HALMAN, J. Conducting and publishing design science research: Inaugural essay of the design science department of the Journal of Operations Management. **Journal of Operations Management**, v. 47-48, p. 1-8, 2016. DOI: 10.1016/j.jom.2016.06.004.

WANG, T.; ZHAO, S.; ZHU, G.; ZHENG, H. A machine learning-based early warning system for systemic banking crises. **Applied Economics**, v. 53, n. 26, p. 2974-2992, 2021. DOI: 10.1080/00036846.2020.1870657.

YANOW, D. Evidence-based policy. **Encyclopedia Britannica**, 2021. Disponível em: <https://www.britannica.com/topic/evidence-based-policy>. Acesso em: 13 dez. 2021.

YOUNG, H. P. Monotonic solutions of cooperative games. **International Journal of Game Theory**, v. 14, p. 65-72, 1985. DOI: /10.1007/BF01769885.

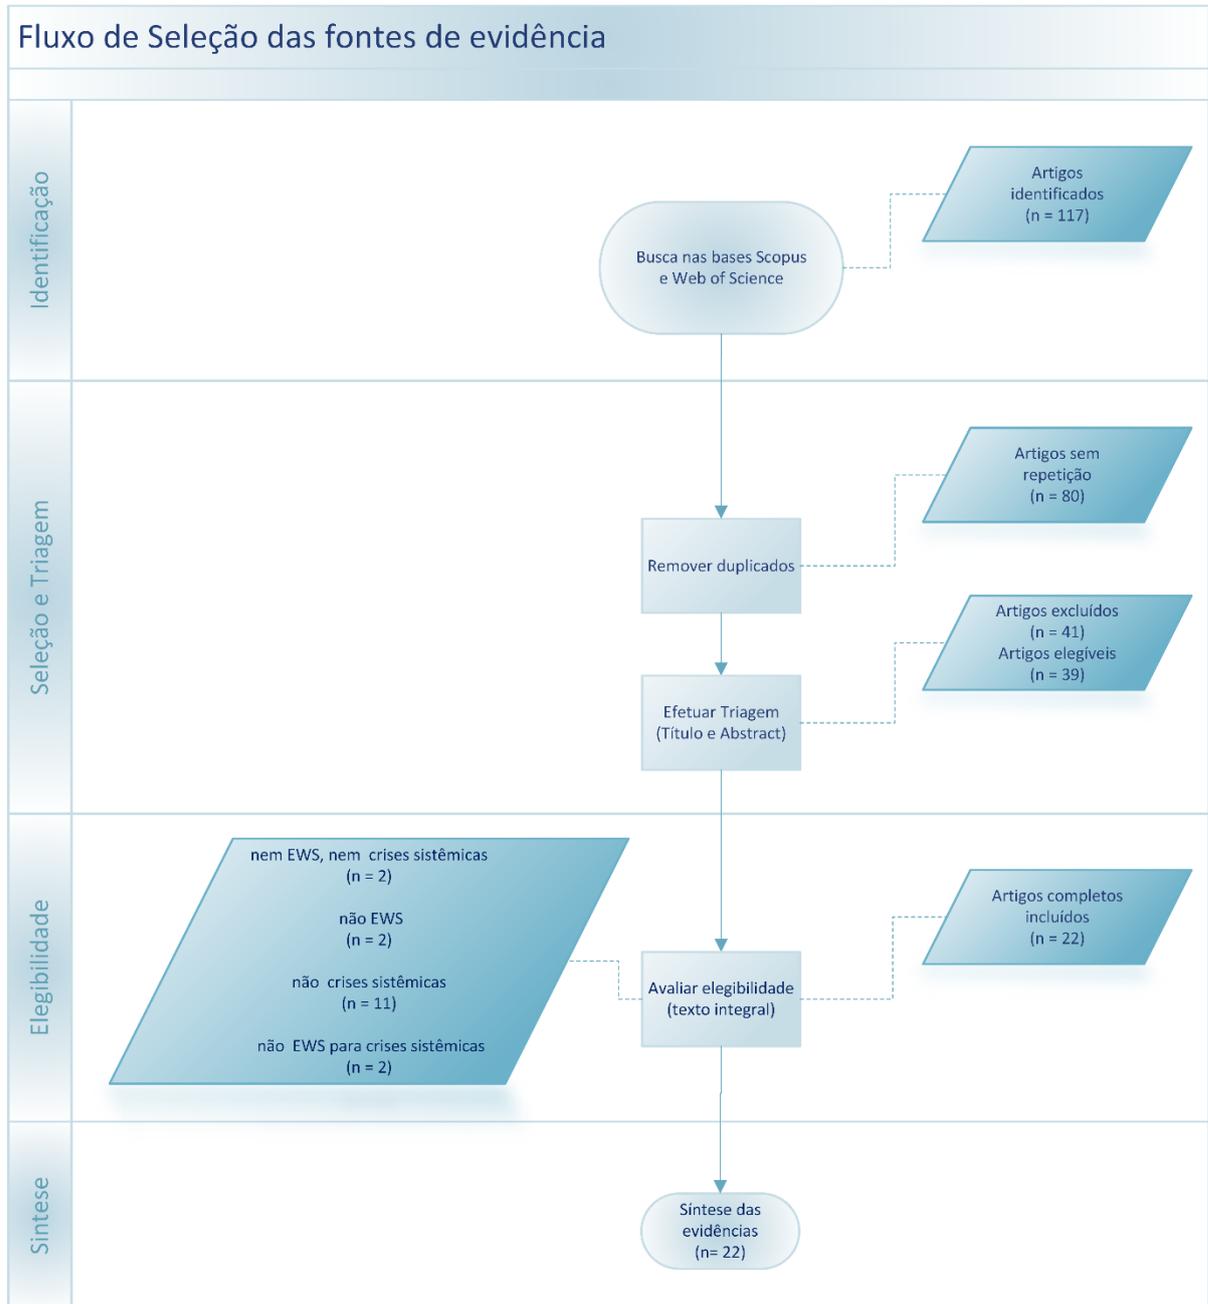
ZIGRAIOVA, D.; JAKUBIK, P. Systemic event prediction by an aggregate early warning system: An application to the Czech Republic. **Economic Systems**, v. 39, n. 4, p. 553-576, 2015. DOI: 10.1016/j.ecosys.2015.04.004.

## APÊNDICE A – Resumo do protocolo da revisão de escopo

Item	Descrição
<b>Questão Norteadora</b>	Quais são as tendências, os métodos e os padrões de alerta ou índices presentes na literatura relacionada a EWS para crises financeiras sistêmicas?
<b>Objetivos</b>	Identificar, sintetizar e traduzir: <ul style="list-style-type: none"> <li>os padrões de alerta, indicadores ou índices encontrados;</li> <li>os métodos, técnicas e ferramentas utilizados;</li> <li>as tendências de desenvolvimento e utilização dos sistemas.</li> </ul>
<b>Critérios de Elegibilidade</b>	Busca pelos termos em inglês e sem limitação temporal, visando alcançar a maior extensão possível da produção científica disponível. Ademais, os termos que resumem a questão de pesquisa, por meio de população, conceito e contexto (PCC), restringem os trabalhos elegíveis àqueles que tratam de EWSs para crises financeiras sistêmicas o que não inclui, portanto, as exclusivamente cambiais, bancárias ou locais (e.g.: crises soberanas).
<b>Fontes de Evidência</b>	As bases de dados selecionadas para pesquisa foram <i>Scopus</i> e <i>Web of Science</i> , tendo em vista que representam, respectivamente, a maior base de dados de resumos e citações com revisão por especialistas e a base que indexa somente os periódicos mais citados em suas áreas de estudo, portanto, priorizou-se a abrangência e qualidade dos trabalhos indexados.
<b>Estratégia de Busca</b>	Foram utilizadas as seguintes <i>strings</i> , executadas, respectivamente, nas bases <i>Scopus</i> e <i>Web of Science</i> : <ol style="list-style-type: none"> <li>(TITLE ("EARLY WARNING" AND "FINANCIAL CRIS*") OR KEY ("EARLY WARNING" AND "FINANCIAL CRIS*")) AND (LIMIT-TO (DOCTYPE,"ar")) AND (LIMIT-TO (SUBJAREA,"ECON") OR LIMIT-TO (SUBJAREA,"BUSI"))</li> <li>(TI=("EARLY WARNING" AND "FINANCIAL CRIS*") OR AK=("EARLY WARNING" AND "FINANCIAL CRIS*")) AND (TASCA==( "ECONOMICS" OR "BUSINESS FINANCE") AND DT==( "ARTICLE"))</li> </ol>
<b>Processo de Seleção e Triagem</b>	Os critérios previamente estabelecidos foram aplicados diretamente na definição da <i>string</i> busca, cuja submissão resultou em 117 trabalhos. De forma mais detalhada, foram obtidos 76 artigos na base <i>Scopus</i> e 41 na <i>Web of Science</i> , que, após a exclusão dos artigos em duplicidade, perfizeram um total de 80 fontes de evidências. Subsequentemente, foi realizada a fase de triagem das fontes de pesquisa por meio da leitura dos <i>abstracts</i> para identificar aquelas com potencial para responder à questão de pesquisa e fornecer as evidências necessárias ao alcance dos objetivos do trabalho. Esse processo resultou na seleção de 41 artigos para leitura do texto integral, quando ainda foram excluídos mais 19 trabalhos, chegando-se a um total de 22 fontes de evidências.
<b>Mapeamento e Síntese dos Dados</b>	Foi desenvolvido um quadro sintético para responder à questão e aos objetivos da pesquisa com os seguintes campos: autores, ano, título, método, indicadores (relevantes) e amostra (período e países).
<b>Avaliação Crítica das Fontes</b>	Não foi realizada uma avaliação crítica das fontes individuais de evidência para aferir a qualidade dos estudos ou o risco de viés, o que é consistente com o Manual do <i>Joanna Briggs Institute</i> (Peters <i>et al.</i> , 2015). Entretanto, foi realizada uma análise bibliométrica dos autores referenciados e palavras-chave utilizadas nos artigos obtidos por meio da aplicação da <i>string</i> de busca que atestam em grande medida a adequação da amostra.

Fonte: Elaborado pelo autor com base na extensão *PRISMA-SCR*

## APÊNDICE B – Seleção das fontes da revisão de escopo



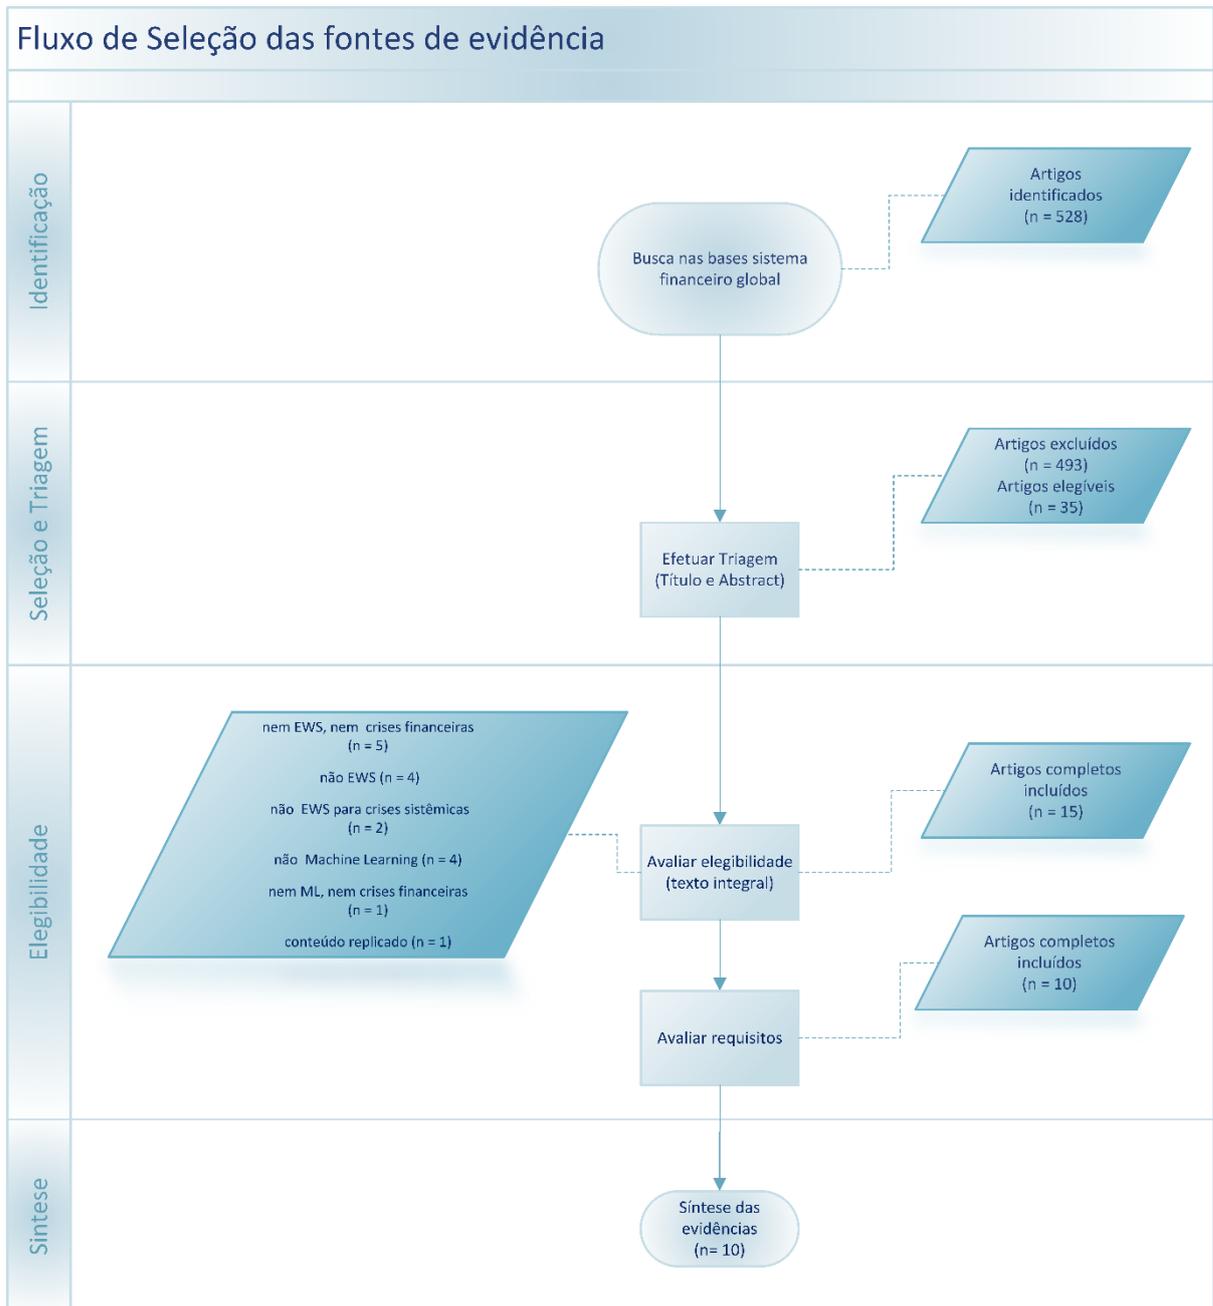
Fonte: Elaborado pelo autor

## APÊNDICE C – Resumo do protocolo da MLR

Item	Descrição
<b>Questão Norteadora</b>	<i>Machine Learning</i> melhora o desempenho dos Sistemas de Alerta Precoce para crises financeiras sistêmicas no âmbito do sistema financeiro global?
<b>Objetivo</b>	Mapear o conhecimento empírico para verificar, com base na prática dos órgãos do sistema financeiro global, se EWS que utilizam técnicas de ML apresentam uma performance preditiva para crises financeiras superior àqueles desenvolvidos sobre técnicas tradicionais.
<b>Critérios de Elegibilidade</b>	<p>Busca pelos termos em inglês e sem limitação temporal, visando alcançar a maior extensão possível da produção científica disponível.</p> <p>Adicionalmente, os termos que resumem a questão de pesquisa, por meio de população, conceito e contexto (PCC), restringem os trabalhos elegíveis àqueles que tratam de EWS que utilizam técnicas de ML para crises financeiras.</p> <p>A relevância para a pesquisa foi analisada a partir dos seguintes requisitos diretamente relacionados às questões de pesquisa, com a ressalva de que o primeiro e o segundo são obrigatórios e o terceiro, desejável:</p> <ol style="list-style-type: none"> <li>1. comparar o desempenho dos métodos baseados em ML aos tradicionais;</li> <li>2. utilizar técnicas objetivas e verificáveis, preferencialmente estatísticas, para medir o desempenho dos modelos; e</li> <li>3. determinar de forma clara o modelo (método + indicadores) que apresentou um desempenho superior.</li> </ol>
<b>Fontes de Evidência</b>	Bases de dados das instituições mais bem classificadas no <i>ranking</i> de bancos centrais IDEAS/RePec.
<b>Estratégia de Busca</b>	<p>O processo de construção da estratégia de busca constou de algumas iterações, que resultaram, após alguns testes em uma <i>string</i> que realizava a pesquisa a partir dos descritores na seção de publicação nas páginas das organizações.</p> <p>Entretanto, como as bases são numerosas e bastante heterogêneas, além da observação prática de que, em algumas buscas, houve exclusão indevida de evidências, optou-se por buscar os descritores na ferramenta de busca geral do <i>site</i>.</p>
<b>Síntese dos Dados</b>	<p>A síntese das informações relevantes seguiu a abordagem recomendada por Garousi <i>et al.</i> (2019), por meio da representação dos estudos selecionados em um quadro analítico comum com informações padronizadas.</p> <p>Com efeito, foi desenvolvido um quadro para responder à questão e aos objetivos da pesquisa com os seguintes campos: autores, métodos, variáveis e técnicas para determinação de causa e efeito em ML.</p>
<b>Avaliação Crítica das Fontes</b>	A avaliação de qualidade teve como base os critérios sugeridos por Garousi <i>et al.</i> (2019) e, seguindo a orientação dos próprios autores, foram adaptados ou retirados os critérios de acordo com o contexto da presente pesquisa e da seleção das fontes.

Fonte: Elaborado pelo autor com base em Garousi *et al.* (2019)

## APÊNDICE D – Seleção das fontes de evidência da MLR



Fonte: Elaborado pelo autor

## APÊNDICE E – Script SMOTE

A seguir está descrito o código utilizado para implementar o algoritmo *SMOTE* no software *Orange Data Mining*.

```
# Carrega bibliotecas
import Orange
import numpy as np
from Orange.data import Domain, Table
from imblearn.over_sampling import SMOTE

# Passa os dados para o widget
df = in_data.copy()

# define parâmetros para o SMOTE
sm = SMOTE(random_state=42)

# Obtém tabela de dados (X) e variáveis de classe (y)
X, y = df.X, df.Y

# Reamostra dados e classes
X_res, y_res = sm.fit_resample(X,y)

# Obtém variáveis alvo e de características
d = Domain(df.domain.attributes, df.domain.class_vars)

# Cria um novo objeto Tabela Orange com os cabeçalhos apropriados e passa os
dados para o próximo widget
out_data = Orange.data.Table(d, X_res, y_res)
```

## ANEXO A – Widget Rank (Orange Data Mining)

### Rank

Ranking of attributes in classification or regression datasets.

### Inputs

Data: input dataset

Scorer: models for feature scoring

### Outputs

Reduced Data: dataset with selected attributes

Scores: data table with feature scores

Features: list of attributes

The **Rank** widget scores variables according to their correlation with discrete or numeric target variable, based on applicable internal scorers (like information gain, chi-square and linear regression) and any connected external models that supports scoring, such as linear regression, logistic regression, random forest, SGD, etc. The widget can also handle unsupervised data, but only by external scorers, such as PCA.

	#	Gai...tio	Gini
thal	3	0.168	0.137
exerc ind ang	2	0.153	0.093
chest pain	4	0.118	0.134
major vessels colored		0.116	0.119
slope peak exc ST	3	0.087	0.075
ST by exercise		0.074	0.095
gender	2	0.063	0.038
max HR		0.062	0.081
age		0.029	0.039
rest ECG	3	0.022	0.016
cholesterol		0.008	0.011
rest SBP		0.008	0.010
fasting blood sugar > 120	2	0.001	0.000

1. Select scoring methods. See the options for classification, regression and unsupervised data in the Scoring methods section.
2. Select attributes to output. None won't output any attributes, while All will output all of them. With manual selection, select the

attributes from the table on the right. Best ranked will output n best ranked attributes. If Send Automatically is ticked, the widget automatically communicates changes to other widgets.

3. Status bar. Produce a report by clicking on the file icon. Observe input and output of the widget. On the right, warnings and errors are shown.

### **Scoring methods (classification)**

1. Information Gain: the expected amount of information (reduction of entropy)
2. Gain Ratio: a ratio of the information gain and the attribute's intrinsic information, which reduces the bias towards multivalued features that occurs in information gain
3. Gini: the inequality among values of a frequency distribution
4. ANOVA: the difference between average values of the feature in different classes
5. Chi2: dependence between the feature and the class as measured by the chi-square statistic
6. ReliefF: the ability of an attribute to distinguish between classes on similar data instances
7. FCBF (Fast Correlation Based Filter): entropy-based measure, which also identifies redundancy due to pairwise correlations between features
8. Additionally, you can connect certain learners that enable scoring the features according to how important they are in models that the learners build (e.g. Logistic Regression, Random Forest, SGD). Please note that the data is normalized before ranking.

### **Scoring methods (regression)**

Univariate Regression: linear regression for a single variable

RReliefF: relative distance between the predicted (class) values of the two instances.

Additionally, you can connect regression learners (e.g. Linear Regression, Random Forest, SGD). Please note that the data is normalized before ranking.

### Scoring method (unsupervised)

Currently, only PCA is supported for unsupervised data. Connect PCA to Rank to obtain the scores. The scores correspond to the correlation of a variable with the individual principal component.

### Scoring with learners

Rank can also use certain learners for feature scoring. See Learners as Scorers for an example.

Example: Attribute Ranking and Selection

Below, we have used the Rank widget immediately after the File widget to reduce the set of data attributes and include only the most informative ones:



Notice how the widget outputs a dataset that includes only the best-scored attributes:

**Data Table**

	iameter narrowin	chest pain	ajor vessels colore	thal
1	0	typical ang	0.000	fixed defect
2	1	asymptomatic	3.000	normal
3	1	asymptomatic	2.000	reversible defect
4	0	non-anginal	0.000	normal
5	0	atypical ang	0.000	normal
6	0	atypical ang	0.000	normal
7	1	asymptomatic	2.000	normal
8	0	asymptomatic	0.000	normal
9	1	asymptomatic	1.000	reversible defect

**Rank**

Missing values have been imputed.

Select Attributes

None  
 All  
 Manual  
 Best ranked: 3

	#	Inf. gain	Gain Ratio	Gini
<b>D</b> thal	3	0.208	0.167	0.068
<b>D</b> chest pain	4	0.205	0.118	0.067
<b>C</b> major vessels colored	C	0.180	0.115	0.059
<b>C</b> ST by exercise	C	0.145	0.074	0.047
<b>D</b> exerc ind ang	2	0.139	0.153	0.046
<b>C</b> max HR	C	0.123	0.062	0.040
<b>D</b> slope peak exc ST	3	0.112	0.087	0.038
<b>C</b> age	C	0.058	0.029	0.020
<b>D</b> gender	2	0.057	0.063	0.019
<b>D</b> rest ECG	3	0.024	0.022	0.008
<b>C</b> cholesterol	C	0.016	0.008	0.006
<b>C</b> rest SBP	C	0.015	0.008	0.005
<b>D</b> fasting blood sugar > 120	2	0.000	0.001	0.000