

UNIVERSIDADE ABERTA



Monitorização de Operações de Risco no Jogo Online

O exemplo do Branqueamento de Capitais

Nuno Alexandre Apolónia do Estanque

Mestrado em Matemática, Estatística e Computação

Dissertação orientada pela

Professora Doutora Alda Cristina Jesus Valentim Nunes de Carvalho

dezembro de 2025



© 2025 Este trabalho está licenciado sob CC BY-NC-SA 4.0. Para ver uma cópia desta licença, visite <http://creativecommons.org/licenses/by-nc-sa/4.0/>.

AGRADECIMENTOS

A realização desta dissertação contou com apoios fundamentais aos quais expresso o meu reconhecimento.

À minha Orientadora, Professora Doutora Alda Carvalho, pela orientação, disponibilidade e pelos conselhos decisivos ao longo deste processo.

Aos Responsáveis do meu Serviço, aos Diretores e Colegas, pela confiança e pela cedência dos dados essenciais à concretização deste estudo.

À minha família. Em especial à Tânia, pelo apoio incondicional; à minha filha Helena, por perdoar as minhas ausências nas brincadeiras; e à Maria, por nunca me deixar desistir.

Para a Helena.



DECLARAÇÃO DE INTEGRIDADE

STATEMENT OF INTEGRITY

Declaro ter atuado com integridade na elaboração da presente dissertação/tese. Confirmando que em todo o trabalho conducente à sua elaboração não recorri à prática de plágio ou a qualquer outra forma de falsificação de resultados.

Mais declaro que tomei conhecimento integral do Regulamento Disciplinar da Universidade Aberta, publicado no Diário da República, 2.^a série, n.º 215, de 6 de novembro de 2013.

I hereby declare having conducted my thesis with integrity. I confirm that I have not used plagiarism or any form of falsification of results in the process of the thesis elaboration.

I further declare that I have fully acknowledged Disciplinary Regulations of the Universidade Aberta (regulation published in the official journal Diário da República, 2.^a série, n.º 215, de 6 de novembro de 2013).

Universidade Aberta, 23 de dezembro de 2025

Nome completo/Full name: Nuno Alexandre Apolónia do Estanque

Assinatura/Signature:

manuscrita ou digital / handwritten or digital

TÍTULO: Monitorização de Operações de Risco no Jogo Online: O exemplo do Branqueamento de Capitais

RESUMO

O setor do jogo online é frequentemente identificado como vulnerável ao branqueamento de capitais e financiamento do terrorismo (BC/FT), em virtude da sua elevada frequência transacional. Esta dissertação propõe uma abordagem de aprendizagem supervisionada para apoiar a monitorização do risco, formulando o problema como uma classificação binária ao nível do jogador.

Com base em dados reais, construíram-se perfis comportamentais agregados que sintetizam a atividade financeira dos jogadores. A modelação recorreu ao algoritmo Random Forest, combinado com validação cruzada estratificada, por forma a lidar com o forte desequilíbrio entre classes.

Os resultados evidenciam a eficácia do modelo na identificação e seleção dos casos mais relevantes, permitindo concentrar uma proporção significativa de jogadores já sinalizados nas primeiras posições de uma lista ordenada por risco. Ao mesmo tempo, a definição de critérios de decisão conservadores mostrou-se coerente com a exigência regulatória de minimizar os casos de falsos negativos. A análise de importância das variáveis indica ainda que os volumes financeiros movimentados e a presença de valores elevados desempenham um papel central na diferenciação dos perfis de risco.

Apesar das limitações associadas a restrições de confidencialidade e a potenciais imperfeições na rotulagem dos dados, conclui-se que a abordagem proposta constitui um contributo relevante para o apoio à monitorização do risco de BC/FT no jogo online, complementando os mecanismos tradicionais de controlo e os processos de análise humana.

PALAVRAS-CHAVE: Jogo online; Branqueamento de capitais; Monitorização de transações; Random Forest; *Score* de risco

TITLE: Monitoring High-Risk Transactions in Online Gambling: A Case Study on Money Laundering

ABSTRACT

The online gambling sector is often identified as vulnerable to money laundering and terrorist financing (BC/FT), due to its high transaction frequency. This dissertation proposes a supervised learning approach to support risk monitoring, framing the problem as a player-level binary classification task.

Using real data, aggregated behavioral profiles were constructed to summarize players' financial activity. Modeling relied on a Random Forest algorithm combined with stratified cross-validation to address the strong class imbalance.

The results show that the model is effective in identifying and prioritizing the most relevant cases, concentrating a substantial share of previously flagged players at the top of a risk-ranked list. At the same time, adopting conservative decision criteria is consistent with regulatory requirements to minimize false negatives. Variable importance analysis further indicates that total financial volumes and the presence of high-value extremes play a central role in differentiating risk profiles.

Despite limitations related to confidentiality constraints and potential labeling imperfections, the proposed approach provides a relevant contribution to supporting BC/FT risk monitoring in online gambling, complementing traditional control mechanisms and human review processes.

KEYWORDS: Online gambling; Anti-money laundering; Transaction monitoring; Random Forest; Risk scoring

ÍNDICE

RESUMO	vi
ABSTRACT	vii
ÍNDICE	viii
ÍNDICE DE FIGURAS	x
ÍNDICE DE TABELAS	xii
ABREVIATURAS, SIGLAS E ACRÓNIMOS	xiii
INTRODUÇÃO	1
CAPÍTULO 1. RISCO E TRANSAÇÕES NO JOGO ONLINE.....	3
1.1 Enquadramento Histórico e Institucional	3
1.2 O Jogo Online em Portugal.....	4
1.3 O Combate ao Branqueamento de Capitais	6
1.4 O Branqueamento de Capitais aplicado ao Jogo Online em Portugal	7
1.5 Avaliação de Riscos e Vulnerabilidades.....	8
1.6 Experiências Internacionais	10
CAPÍTULO 2. REVISÃO DA LITERATURA E ESTADO DA ARTE	13
2.1 Enquadramento	13
2.2 Abordagens à deteção de risco de branqueamento de capitais	14
2.3 Abordagens da literatura no contexto do jogo online	17
2.4 Síntese crítica das abordagens metodológicas	19
CAPÍTULO 3. MONITORIZAÇÃO DE TRANSAÇÕES E AVALIAÇÃO DO RISCO DE BC/FT	23
3.1 Dados	23
3.2 Metodologia	30
3.2.1 Exemplo ilustrativo de agregação ao nível do jogador	35

3.3 Fundamentos dos modelos de árvore e Random Forest	37
3.3.1 Árvores de decisão e o método CART.....	39
3.3.2 Bootstrap e Bagging: motivação e formalização.....	40
3.3.3 Random Forest: introdução de aleatoriedade adicional	41
3.3.4 Importância das variáveis, interpretação, avaliação e validação.....	43
3.4 Modelação.....	45
3.5 Análise de resultados	46
3.5.1 Desempenho global do modelo	46
3.5.2 Avaliação do poder discriminatório e ordenação por risco.....	49
3.5.3 Interpretação do modelo e priorização de casos.....	53
3.5.4 Definição do limiar de decisão e implicações operacionais.....	58
CONCLUSÃO	60
BIBLIOGRAFIA.....	63
ANEXOS.....	70
Anexo A — Análises complementares e representações gráficas adicionais.....	71

ÍNDICE DE FIGURAS

Figura 1. 1 - Evolução da Receita Bruta (2017-2024). Nota. Dados do SRIJ.....	5
Figura 1. 2 - Distribuições JFA vs. ADC (2017-2024). Nota. Dados do SRIJ.....	5
Figura 2. 1 - Interpretação de resultados.	15
Figura 2. 2 - Métodos não supervisionados (exploratórios) vs. supervisionados (preditivos).	20
Figura 3. 1 - Boxplot do SALDO_MOV (escala original).	26
Figura 3. 2 - Distribuição do SALDO_MOV, em escala logarítmica, com histogramas normalizados e curva empírica sobreposta.	27
Figura 3. 3 - Número de operações por jogador (escala logarítmica), por grupo.....	28
Figura 3. 4 - Esquema conceptual do Random Forest.....	42
Figura 3. 5 - Matriz de confusão (heatmap), para o limiar adotado.	48
Figura 3. 6 - Evolução das métricas em função do limiar de decisão.	49
Figura 3. 7 - Curva ROC.	50
Figura 3. 8 - Curva Precisão–Revocação.....	51
Figura 3. 9 - Distribuição dos scores de risco por classe.....	52
Figura 3. 10 - Distribuição contínua dos scores (densidade) por classe.....	53
Figura 3. 11 - Relevância das variáveis (Top 10).	55
Figura 3. 12 - Curva de ganho cumulativo.	56
Figura 3. 13 - Score médio do Top-N ao longo do ranking de risco.	57
Figura A. 1 - Curva de calibração.....	71
Figura A. 2 - Curva de ganho cumulativo.	72
Figura A. 3 - Curva de lift.	73

Figura A. 4 - Importância das variáveis (top 15).....	74
Figura A. 5 - Curvas de dependência parcial (PDP).....	75
Figura A. 6 - Matriz de correlação das variáveis agregadas.....	76
Figura A. 7 - Volume total movimentado por decis de score.....	77
Figura A. 8 - Duração da atividade por decis de score.....	78
Figura A. 9 - Percentil 99 dos montantes movimentados por decis de score.	79

ÍNDICE DE TABELAS

Tabela 3. 1 - Variáveis.....	24
Tabela 3. 2 - Número de operações por tipo de código de operação.....	25
Tabela 3. 3 - Estatísticas descritivas do SALDO_MOV.	28
Tabela 3. 4 - Número de operações por jogador.....	29
Tabela 3. 5 - Atividade contínua do jogador, em dias.....	30
Tabela 3. 6 - Variáveis agregadas ao nível do jogador.....	32
Tabela 3. 7 - Estabilidade das métricas no conjunto de teste.	47
Tabela 3. 8 - Variáveis mais relevante.	54
Tabela 3. 9 - Concentração de casos positivos.	56
Tabela 3. 10 - Impacto do limiar no volume de alertas e desempenho.	58

ABREVIATURAS, SIGLAS E ACRÓNIMOS

ADC – Apostas Desportivas à Cota

AMLA – Anti-Money Laundering Authority (Autoridade Europeia de Combate ao Branqueamento de Capitais)

AUSTRAC – Australian Transaction Reports and Analysis Centre

BC – Branqueamento de Capitais

BC/FT – Branqueamento de Capitais e Financiamento do Terrorismo

BdP – Banco de Portugal

CART – Classification and Regression Trees

CCTV – Closed-Circuit Television

COS – Comunicação de Operação Suspeita

CRISP-DM – Cross-Industry Standard Process for Data Mining

DCIAP – Departamento Central de Investigação e Ação Penal

EGBA – European Gaming and Betting Association

FIU – Financial Intelligence Unit

FinCEN – Financial Crimes Enforcement Network (Estados Unidos da América)

FT – Financiamento do Terrorismo

GAFI/FATF – Grupo de Ação Financeira Internacional / Financial Action Task Force

GGR – Gross Gaming Revenue

GREF – Gaming Regulators European Forum

JFA – Jogos de Fortuna ou Azar

KYC – Know Your Customer

KYC/CDD – Know Your Customer / Customer Due Diligence

LBCFT – Lei n.º 83/2017 de 18 de agosto

PIB – Produto Interno Bruto

RCBE – Registo Central do Beneficiário Efetivo

RJO – Regime Jurídico dos Jogos e Apostas Online

SCML – Santa Casa da Misericórdia de Lisboa

SRIJ – Serviço de Regulação e Inspeção de Jogos

UIF – Unidade de Informação Financeira

XML – Extensible Markup Language

INTRODUÇÃO

O jogo tem sido historicamente percecionado como um setor vulnerável ao branqueamento de capitais e financiamento do terrorismo (BC/FT), em virtude da elevada circulação de dinheiro, da velocidade das transações e da possibilidade de dissimulação de fluxos financeiros através da atividade lúdica.

A prática e a literatura internacional (Financial Transactions and Reports Analysis Centre of Canada [FINTRAC], 2024; Levi, 2009) têm alertado para a existência de um elevado número de riscos associados especificamente, neste âmbito, ao jogo online. Tratam-se de ameaças associadas a práticas como o *smurfing* (fragmentação de depósitos em múltiplas contas), o *chip dumping* (transferência dissimulada de fichas em jogos de póquer), o *gnoming* (uso de identidades múltiplas para manipulação de resultados ou dispersão de fluxos), depósitos significativos seguidos de ausência de atividade de jogo, levantamentos superiores ao total de ganhos justificados, uso intensivo de carteiras digitais e cartões pré-pagos, ou incoerências entre os métodos de depósito e de levantamento, só para dar alguns exemplos.

Estes comportamentos, quando detetados, constituem *red flags*, verdadeiros *markers of harm*¹, numa analogia com a terminologia utilizada para o risco associado ao jogo responsável, ou seja, podem-se constituir como indicadores de alerta úteis que, isoladamente ou combinados, podem revelar tentativas de dissimular a origem ilícita de fundos através da atividade de jogo.

A identificação destas práticas, até pelo seu grande número, está longe de ser um exercício linear, sendo a sua deteção raramente direta ou facilmente observável. É, pois, neste equilíbrio entre robustez estrutural e riscos emergentes, que se insere a necessidade de desenvolver modelos estatísticos e computacionais que permitam diferenciar comportamentos legítimos de operações potencialmente ilícitas. O desafio não é apenas detetar a anomalia estatística, mas sobretudo identificar quando esta constitui um sinal de risco relevante em termos de BC/FT.

As experiências internacionais mostram que falhas de monitorização resultam frequentemente em sanções pesadas e danos reputacionais para os operadores, para os

¹ Para uma definição formal, consultar o *draft* da norma europeia CEN sobre *markers of harm* (European Committee for Standardization, 2024).

reguladores e para o próprio país, reforçando a pertinência de estudos acadêmicos que desenvolvam soluções inovadoras.

Neste quadro, a presente dissertação justifica-se como um contributo duplo: por um lado, testa metodologias estatísticas e computacionais para deteção automática de padrões suspeitos; por outro, alinha-se com a evolução regulatória europeia, antecipando a integração do setor do jogo nas práticas harmonizadas em matéria de prevenção e combate ao BC/FT.

CAPÍTULO 1. RISCO E TRANSAÇÕES NO JOGO ONLINE

1.1 Enquadramento Histórico e Institucional

A aceitação em Portugal do jogo de fortuna ou azar como uma realidade efetiva teve respaldo no Decreto n.º 14643, de 3 de dezembro de 1927, desde logo justificada pela necessidade de “*reduzir ao mínimo os abusos*” e “*cortadas mais cerces as tam apregoadas nefastas conseqüências do jôgo*”. Até então as únicas formas social e legalmente aceites de jogo, eram as ligadas à beneficência e às ordens sociais — práticas que, com o passar do tempo, evoluíram para os atuais jogos sociais da Santa Casa da Misericórdia de Lisboa (SCML) e que dos primeiros se distinguem.

Umbilicalmente ligados e interdependentes da promoção turística, os jogos de fortuna ou azar desenvolveram-se em Portugal sob um quadro jurídico e regulatório particularmente exigente. Durante décadas, o setor manteve-se relativamente estável e pouco mutável, até que o surgimento da internet provocou o grande cisma que marcou o aparecimento e a expansão do jogo online, dividindo o universo do jogo entre o espaço físico (jogo de base territorial) e o digital (jogo online). Inicialmente ilegal, à semelhança do que acontecera em 1927, o Estado acabaria por reconhecer e integrar esta nova realidade, trazendo-a para a sua esfera jurídica através da aprovação do Regime Jurídico dos Jogos e Apostas Online (RJO), estabelecido pelo Decreto-Lei n.º 66/2015, de 29 de abril.

Assim, a consolidação do enquadramento jurídico atual do setor do jogo em Portugal² resultou da articulação entre a chamada Lei do Jogo³ — aplicável à exploração de jogos de fortuna ou azar de base territorial — e o RJO. Este duplo regime é supervisionado pelo Serviço de Regulação e Inspeção de Jogos (SRIJ), entidade integrada no Turismo de Portugal, I.P., mas dotada de autonomia técnica e funcional, nos termos da respetiva lei orgânica⁴.

O SRIJ exerce poderes de autoridade pública administrativa, competindo-lhe regular, fiscalizar e inspecionar tanto a exploração de jogos de fortuna ou azar de base territorial

² Excluindo os chamados jogos sociais, que sempre se mantiveram sob a alçada da SCML.

³ Aprovada pelo Decreto-Lei n.º 422/89, de 2 de dezembro.

⁴ Decreto-Lei n.º 129/2012, de 22 de junho, na sua redação atual.

como as atividades de jogos e apostas online, garantindo o cumprimento da lei e a integridade do setor.

A arquitetura institucional distingue dois polos complementares. Por um lado, o SRIJ, que assegura a componente operacional de supervisão e inspeção, conduzindo auditorias, verificações e ações inspetivas, bem como acompanhando de forma contínua a atividade dos operadores. Por outro, a Comissão de Jogos, que atua como órgão colegial de decisão independente, cabendo-lhe a emissão de regulamentos, a atribuição de concessões e licenças, a definição de orientações estratégicas e a aplicação de sanções⁵. Esta separação orgânica assegura a segregação funcional, evitando conflitos de interesse entre as funções de controlo quotidiano e as de decisão sancionatória ou regulatória de maior alcance.

1.2 O Jogo Online em Portugal

Nos termos da lei, a exploração de jogos e apostas online em Portugal encontra-se reservada ao Estado, sendo atribuída a entidades privadas mediante licença emitida pelo SRIJ.

De acordo com o relatório de registo da atividade de jogo online em Portugal no 3.º trimestre de 2025, encontram-se licenciadas 17 entidades exploradoras de jogo online, correspondendo a 30 diferentes licenças para a oferta de jogos de fortuna ou azar e de apostas desportivas⁶.

Desde a entrada em vigor RJO em 2015, e a emissão da primeira licença em 2016, o mercado português de jogo online tem registado um crescimento sustentado e significativo. Os relatórios anuais do SRIJ evidenciam que, no período entre 2016 e o dia 30 de setembro de 2025, o número acumulado de registos de jogadores já superou os 4,5 milhões⁷, sendo que 25% destes, aparentavam estar ativos⁸ nos últimos 356 dias.

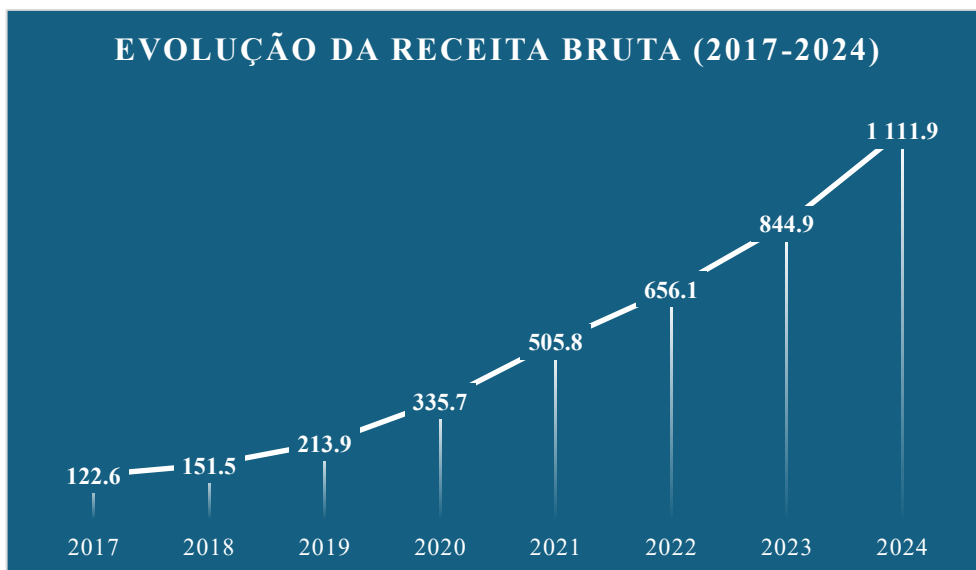
Em termos de volume financeiro, a receita bruta do jogo online ou *Gross Gaming Revenue* (GGR) passou de cerca de 122,6 milhões de euros, no ano de 2017, para mais de 1 111,9 milhões em 2024, representando um aumento superior a 800% em sete anos.

⁵ Respetivamente Art. 9.º n.º 2 e Art. 7.º da Lei Orgânica.

⁶ Este número foi, entretanto, atualizado para 18 entidades exploradoras e 32 licenças, incluindo uma referente ao jogo do Bingo.

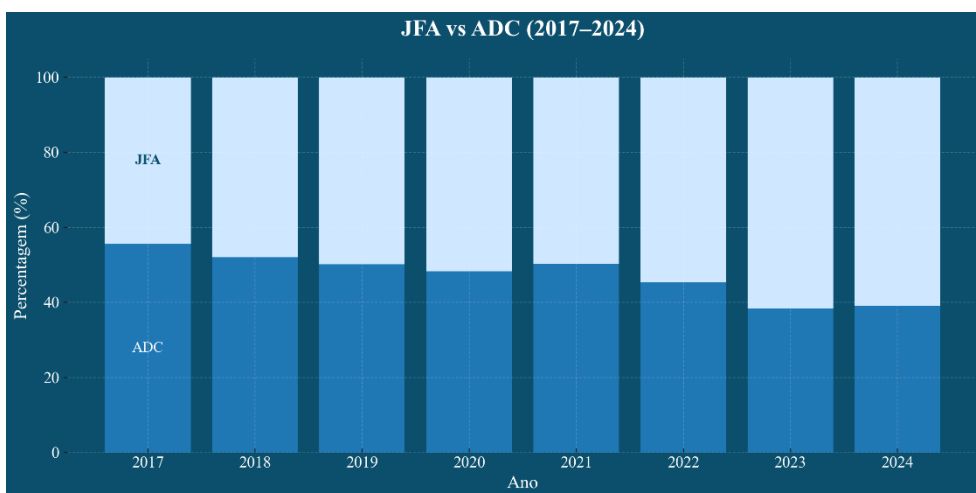
⁷ O número de registos não corresponde ao número de pessoas. Um mesmo indivíduo pode estar registado em uma ou mais entidades exploradoras.

⁸ Realizaram pelo menos uma operação de jogo.



*Figura 1. 1 - Evolução da Receita Bruta (2017-2024).
Nota. Dados do SRIJ⁹*

A oferta tem-se mantido relativamente estável desde a regulamentação do sector, registando-se apenas a entrada de um novo jogo de fortuna ou azar – o Saque ou *Crash*. Ainda assim observa-se um aumento progressivo do peso relativo dos jogos de fortuna ou azar (JFA), categoria que inclui o Póquer, as Roletas, o *Blackjack/21* ou as Máquinas de Jogo, entre outros, face às apostas desportivas à cota (ADC).



*Figura 1. 2 - Distribuições JFA vs. ADC (2017-2024).
Nota. Dados do SRIJ*

⁹ Nota: Nos elementos gráficos, utiliza-se o ponto como separador decimal.

Esta segmentação pode revelar-se relevante, na medida em que diferentes modalidades de jogo apresentam características próprias e, conseqüentemente, perfis de risco distintos. As apostas desportivas à cota, por dependerem de limites de liquidez e de eventos externos, parecem, num mercado relativamente pequeno como o português, ser menos adequadas à movimentação de valores muito elevados. Já modalidades como o Póquer ou a Roleta, pela sua maior flexibilidade ou regularidade mecânica, poderão, em abstrato, oferecer condições mais favoráveis a esse tipo de operações. Importa, contudo, salientar que estas considerações têm natureza essencialmente conceptual e não constituem evidência empírica sobre a prática efetiva destas modalidades.

1.3 O Combate ao Branqueamento de Capitais

O crime de branqueamento de capitais encontra-se tipificado no artigo 368.º-A do Código Penal, punindo, entre muitos outros, a conversão, transferência, ocultação ou dissimulação da origem de bens provenientes de atividade criminosa.

Em Portugal, as políticas de prevenção e combate ao Branqueamento de Capitais, ao Financiamento do Terrorismo e ao Financiamento da Proliferação de Armas de Destruição em Massa (BC/FT) assentam num conjunto articulado de diplomas legais e mecanismos institucionais que procuram assegurar a prevenção, deteção e repressão deste tipo de fenómenos.

O seu principal instrumento, a Lei n.º 83/2017 de 18 de agosto (doravante LBCFT) que estabelece as “medidas de natureza preventiva e repressiva de combate ao branqueamento de capitais e ao financiamento do terrorismo”, transpõe parcialmente para o ordenamento jurídico português, as Diretivas 2015/849/UE do Parlamento Europeu e do Conselho, e 2016/2258/UE do Conselho. Esta lei, não só delimita o âmbito da sua própria aplicação, como define quem são as entidades obrigadas à promoção destas políticas (entidades obrigadas), como ainda estabelece os princípios basilares e os deveres que as estas estão obrigadas. Deveres como o de identificação (*know your customer* – KYC), de diligência reforçada, de exame, de conservação de documentos, de abstenção da realização de transações ou, de obrigação de comunicação de operações suspeitas (COS) à Unidade de Informação Financeira (UIF) e ao Departamento Central de Investigação e Ação Penal (DCIAP), após a sua deteção.

A Lei n.º 89/2017, de 21 de agosto, referente à criação do Registo Central do Beneficiário Efetivo (RCBE), ferramenta essencial para a prevenção do uso abusivo de estruturas societárias com fins de dissimulação de fluxos financeiros ilícitos, a Lei n.º 58/2020, de 31 de agosto, relativa à prevenção da utilização do sistema financeiro para fins de BC/FT, e o seu combate através do direito penal, a Portaria n.º 310/2018, de 4 de dezembro, que define as tipologias de operações a comunicar pelas entidades obrigadas, ou a Portaria n.º 233/2018, de 21 de agosto, que regula o funcionamento do RCBE, densificam o quadro normativo nesta matéria.

A nível institucional, a Comissão de Coordenação das Políticas de Prevenção e Combate ao Branqueamento de Capitais e ao Financiamento do Terrorismo assegura a articulação entre autoridades públicas, elaborando relatórios anuais sobre o risco nacional e promovendo a cooperação interinstitucional. A coordenação operacional é partilhada pela UIF, pelo Banco de Portugal (BdP) e pelas várias autoridades sectoriais como é o caso do SRIJ.

Em alinhamento com os padrões do Grupo de Ação Financeira Internacional (GAFI/FATF), Portugal desenvolve políticas de supervisão baseadas no risco, sujeitas a avaliações periódicas internacionais. O sistema nacional visa garantir um equilíbrio entre a prevenção eficaz e a proporcionalidade das medidas aplicadas, assegurando simultaneamente a integridade do sistema financeiro e a proteção dos direitos fundamentais (Banco de Portugal, s.d.).

1.4 O Branqueamento de Capitais aplicado ao Jogo Online em Portugal

O cumprimento das obrigações em matéria de combate ao BC/FT no âmbito do jogo online regulado parte de uma posição aparentemente favorável.

Por um lado, todo o modelo previsto foi desenhado tendo em atenção essa questão. Logo no preâmbulo do diploma que aprova o RJO, é evidenciada a preocupação que houve em criar “soluções jurídicas” adequadas à “prosecução dos objetivos de interesse público”, nomeadamente no que respeita à prevenção e combate ao branqueamento de capitais. Desde logo apenas “pessoas coletivas privadas, constituídas sob a forma de sociedade anónima ou equivalente, com sede num Estado-Membro da União Europeia, ou num Estado signatário do Acordo sobre o Espaço Económico Europeu que esteja vinculado à cooperação administrativa no domínio da fiscalidade e do combate à fraude e ao branqueamento de

capitais”, se podem candidatar e ver-lhes ser atribuídas licenças para a exploração de jogos e apostas online¹⁰.

Por outro lado, dada a homogeneidade do produto/serviço oferecido, a especificidade do mercado e as obrigações subjacentes, a generalidade das entidades exploradoras de jogo online que têm obtido licença, ou já operam em múltiplas jurisdições com enquadramentos regulatórios semelhantes, ou acumulam experiência prévia na exploração do jogo de base territorial, apresentam um elevado grau de conhecimento e maturidade nesta matéria. Consequentemente, dispõem, em regra, de estruturas internas e de profissionais especificamente designados para assegurar o cumprimento das obrigações em matéria de *compliance* e de combate ao BC/FT, quer decorrentes da legislação específica, quer das exigências próprias do RJO.

Acresce que um dos aspetos distintivos do modelo português reside na grande rastreabilidade (teórica) das transações. No jogo online regulado, todas as operações de depósito e levantamento são realizadas exclusivamente por via eletrónica, unicamente através de prestadores de serviços de pagamento devidamente autorizados pelas autoridades competentes e cujos instrumentos permitam a correta identificação do ordenante. Não há desta forma a hipótese real de utilização de numerário. Mais, a titularidade da conta de pagamento associada a cada jogador é previamente verificada, sendo apenas possível a movimentação de fundos, designadamente levantamentos, para uma conta pertencente ao próprio titular. Esta medida procura dificultar a dispersão de fundos por intermédio de terceiros e promover a denominada *closed-loop rule* (Gambling Commission, 2025), segundo a qual a origem e o destino dos fundos devem coincidir.

1.5 Avaliação de Riscos e Vulnerabilidades

No plano global, o cumprimento das políticas de prevenção do branqueamento de capitais e do financiamento do terrorismo é supervisionado pelo GAFI/FATF. Este organismo intergovernamental, do qual Portugal é membro, avalia periodicamente os países com base em relatórios de avaliação mútua, medindo a eficácia dos sistemas de prevenção e repressão do BC/FT.

¹⁰ Art.º 9.º n.º 1, do RJO.

O setor do jogo é identificado pelo GAFI/FATF como um dos setores não financeiros particularmente vulneráveis (Financial Action Task Force, 2009), sendo frequentemente objeto de recomendações específicas nas suas avaliações e relatórios temáticos, dado o grande volume de numerário envolvido ou a natureza transnacional de muitas operações de jogo. Estas recomendações tipicamente abrangem desde requisitos de identificação e diligência de clientes (KYC/CDD) até à monitorização de transações suspeitas, reforçando a necessidade de controlos eficazes.

No caso português, dadas as naturezas específicas, os riscos e as formas de os tentar mitigar, são passíveis de ser diferenciados por subsetor.

Nos casinos (físicos), o uso intensivo de numerário, obriga à existência de regras específicas, incluindo a identificação obrigatória de frequentadores a partir de €2000¹¹ em transações, o bloqueio automático de máquinas de jogo quando atingem este montante, a presença de *pagadores* em cada mesa de jogo tradicional e a monitorização permanente pelo corpo inspetivo e pelo CCTV (televisão de circuito fechado). Estas medidas reduzem a probabilidade de que uma ação dissimulada passe despercebida. Não obstante a real utilização de dinheiro “vivo”, ainda que condicionada, permanece sempre como um fator de risco principal.

Já o Bingo, porque envolve em regra transações de montantes limitados, é percebido como um jogo de risco reduzido em matéria de BC/FT. A única exceção relaciona-se com o prémio especial acumulado, que pode ultrapassar €2000. Nestes casos, a lei obriga à identificação completa do vencedor, diminuindo os riscos de interposição de terceiros.

Por fim no caso do jogo online, subsistem questões associadas a fenómenos comportamentais e padrões financeiros atípicos, como *smurfing*, o *chip dumping* ou o *gnoming*, entre muitos outros exemplos (FINTRAC, 2024; Levi, 2009). Contudo, dada a contratação à distância, a sua deteção apenas pode ser atingida por outros métodos, como abordagens estatísticas mais sofisticadas.

E se por um lado, o efetivo crescimento desta indústria, como os números o demonstram¹², reflete a consolidação do mercado regulado, o que é bom, por outro, também potencia um

¹¹ Art.º 23.º n.º 2, da LBCFT.

¹² Ver Capítulo 1.2.

maior risco agregado, na medida em que o número de transações processadas pelas plataformas se multiplica em escala e complexidade, o que pode ser pernicioso.

É certo que o licenciamento restrito, a proibição de uso de numerário, a rastreabilidade total e o reporte sistemático, mitigam significativamente a superfície de risco deste subsetor em Portugal, quando se compara com outras jurisdições mais permissivas ou com as restantes atividades económicas. Não obstante, em lado algum se pode considerar que o setor do jogo online está isento de quaisquer vulnerabilidades.

1.6 Experiências Internacionais

Na União Europeia, países como Malta e Chipre enfrentaram avaliações críticas em relatórios do GAFI/FATF, sobretudo devido ao papel do jogo online em esquemas transfronteiriços. Estes casos enfatizam a necessidade das tais metodologias analíticas robustas, pois mesmo regimes regulatórios maduros que o português, podem falhar se não acompanharem a evolução tecnológica das plataformas de jogo.

E ainda assim a literatura académica apresenta uma perspetiva mais matizada, pelo menos para o caso da variante regulada europeia, concluindo que os riscos de branqueamento em jogos de fortuna ou azar, ainda que existam, são comparativamente “modestos” (Levi, 2009, p. 545), quando comparados com outras jurisdições (extra união), resultado da rastreabilidade das operações e da implementação de mecanismos de identificação e controlo, que dificultam a utilização abusiva das plataformas para fins ilícitos.

Vários desses reguladores internacionais têm identificado casos práticos e aplicado sanções avultadas por falhas em mecanismos de prevenção, quer no jogo de base territorial (*vulgo* casinos), quer no jogo online, quer em regimes híbridos, onde as duas realidades coabitam quase indiferenciadamente.

No Reino Unido, a Gambling Commission aplicou múltiplas multas a operadores por deficiências em políticas de KYC e de monitorização de transações. Em 2022, por exemplo, a Entain plc, operador de jogo online, foi multada em 17 milhões de libras, em parte devido a falhas na deteção de padrões de depósitos anómalos por clientes de elevado risco (Gambling Commission, 2022).

Na Austrália, a Australian Transaction Reports and Analysis Centre (AUSTRAC) abriu processos contra operadores de casinos por incumprimento sistemático de deveres de reporte e deficiências na identificação de beneficiários efetivos, sublinhando que os casinos foram utilizados para movimentar fundos ilícitos através de apostas e fichas (AUSTRAC, 2022a, 2022b).

Já nos Estados Unidos, os casinos de Las Vegas, que atuam sob um regime de exploração híbrido (oferta de jogo físico e póquer online), têm sido alvo de escrutínio contínuo por parte da Financial Crimes Enforcement Network (FinCEN). Casos documentados envolvem o uso de fichas e vouchers para introduzir numerário de origem ilícita no sistema financeiro, ocultando a sua proveniência através de levantamentos subsequentes em formato bancário (U.S. Department of the Treasury, 2022).

Estas experiências internacionais têm oferecido lições úteis a todos os países que promovem políticas nesta área: a necessidade de cooperação e cruzamento de informação entre entidades e o reforçar metodologias estatísticas de deteção de risco e alinhar a supervisão nacional com os padrões internacionais.

Neste contexto, o SRIJ, enquanto autoridade sectorial no âmbito do jogo online, procura implementar de sistemas internos de monitorização automatizada de transações e verificação em função do risco, assegurando a sua conformidade.

Paralelamente, à cooperação com a UIF, o DCIAP e órgãos de polícia criminal, mantém também uma presença ativa em fóruns internacionais como o Gaming Regulators European Forum (GREF), a European Gaming and Betting Association (EGBA), e nos trabalhos preparatórios da European Authority for Anti-Money Laundering and Countering the Financing of Terrorism (AMLA)¹³, no que ao jogo diz respeito.

A AMLA, enquanto autoridade europeia para o setor financeiro e não financeiro em matéria de combate ao BC/FT, terá um ramo dedicado o jogo online, com funções de coordenação e harmonização de práticas entre reguladores nacionais. Tal significa que as orientações da AMLA, a médio prazo, afetarão diretamente a forma como os operadores de jogo online são

¹³ O processo de implementação da AMLA encontra-se em curso, após a adoção do Regulamento (UE) 2024/1620, de 31 de maio de 2024. Esta nova Autoridade Europeia, com sede em Frankfurt, iniciou a sua atividade em meados de 2025 e tem como objetivo reforçar a supervisão direta de entidades financeiras selecionadas, coordenar as Unidades de Informação Financeira (FIUs) nacionais e promover a convergência regulatória.

supervisionados em Portugal, particularmente no que se refere a metodologias de análise de risco, indicadores de suspeição e interoperabilidade dos sistemas de reporte.

CAPÍTULO 2. REVISÃO DA LITERATURA E ESTADO DA ARTE

2.1 Enquadramento

O estudo do branqueamento de capitais (BC) e do financiamento do terrorismo (FT) através da análise de dados transacionais constitui uma área de investigação em rápida expansão, tanto no plano académico como no regulatório. Já em 2011, em resultado de uma meta-análise de vários estudos, estimava-se que entre 2,3% e 5,5% do Produto Interno Bruto (PIB) mundial estivesse associado a fluxos ilícitos relacionados com várias formas de BC (United Nations Office on Drugs and Crime, 2011, p. 9), o que representa não apenas um risco sistémico para a estabilidade das economias, mas também uma ameaça direta à integridade das instituições financeiras e não financeiras.

O desafio principal resulta da raridade estatística das transações ilícitas, frequentemente escondidas entre milhões de operações legítimas, e da sua natureza intencionalmente dissimulada. Esta combinação de escassez de casos positivos e semelhança com comportamentos legítimos torna a deteção automática um problema particularmente complexo, exigindo metodologias capazes de conciliar sensibilidade e precisão.

No domínio do jogo online, a vulnerabilidade é acentuada por características intrínsecas ao próprio modelo de negócio. Trata-se de uma atividade marcada por um volume elevado de pequenas transações realizadas a alta frequência¹⁴, à qual se somam a natureza transfronteiriça das plataformas, a liquidez imediata dos fundos e o anonimato relativo potenciado pelo ambiente digital.

Apesar desta aparente necessidade, a literatura científica dedicada especificamente ao cruzamento entre o jogo online e o branqueamento de capitais permanece ainda escassa, sobretudo quando comparada com a existente para o setor bancário ou para o ecossistema das *fintech*, enquanto atividades igualmente intensivas em transações digitais.

Neste contexto, torna-se pertinente recorrer, sempre que existam, a simetrias metodológicas com outros domínios mais estudados e, quando estas não se revelem suficientes, procurar

¹⁴ A generalidade dos jogos online tem inscrito nas suas próprias regras básicas, o conceito de aposta máxima, o que potencia o número de transações. É uma característica inerente aos jogos em geral e aos jogos de fortuna ou azar em particular: com pouco fazer muito. Já há 40 anos a SMCL promovia o Totoloto com um *é fácil é barato e dá milhões*.

soluções em abordagens alternativas já testadas noutros contextos. A análise crítica de percursos metodológicos relativamente consistentes, nos quais diferentes técnicas tenham sido experimentadas, permite identificar estratégias mais adequadas à deteção de comportamentos de risco neste setor específico.

2.2 Abordagens à deteção de risco de branqueamento de capitais

A literatura dedicada à deteção de branqueamento de capitais e financiamento do terrorismo (BC/FT), baseada na análise de dados financeiros e transacionais, caracteriza este fenómeno como particularmente complexo, não apenas pela sua raridade estatística, mas sobretudo, tal como já referido, pela sua natureza intencionalmente dissimulada. Ao contrário de outras formas de fraude financeira, os comportamentos associados ao BC, no seu sentido lato, tendem a imitar padrões legítimos de atividade económica, sendo concebidos para evitar mecanismos de controlo e monitorização.

Esta característica estrutural condiciona profundamente a forma como o problema é abordado na investigação académica, sendo essa dificuldade patente pela extrema dificuldade de operacionalização de sistemas autónomos de supervisão. Veja-se o exemplo do goAML. Este é um aplicativo proposto em 2006 (AMLYZE, 2025) e que se encontra em desenvolvimento há pelo menos 15 anos. Contudo, a sua implementação tem esbarrado consistentemente na dificuldade de definir padrões comuns que, simultaneamente, permitam a recolha de informação proveniente de múltiplas jurisdições, cada uma com regras, obrigações e enquadramentos legais distintos.

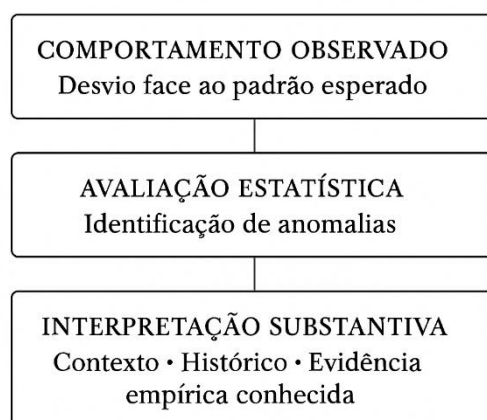
Ainda assim, uma primeira linha de abordagem, historicamente dominante, e que tem sido sugerida, assenta em sistemas baseados em regras e indicadores de risco predefinidos. Estes sistemas recorrem a limiares fixos, por exemplo, sinalizar operações acima de determinado valor, tipologias conhecidas e critérios normativos¹⁵ para sinalizar transações ou entidades potencialmente suspeitas. Trabalhos de natureza mais institucional e regulatória, como os analisados por Jančíková e Veselovská (2018), evidenciam que estas abordagens continuam a desempenhar um papel relevante no cumprimento formal das obrigações de reporte. No entanto, a literatura é consistente ao sublinhar as suas limitações, nomeadamente a rigidez

¹⁵ Que a lei ou regulador mandam vigiar.

face à evolução dos comportamentos ilícitos, a dificuldade de adaptação a novos padrões e a tendência para gerar volumes elevados de alertas que se acabam por mostrar, na prática, pouco relevantes do ponto de vista investigativo.

Em resposta a estas limitações, um conjunto significativo de estudos passou a privilegiar abordagens centradas na análise comportamental e na construção de perfis de risco. Nesta perspetiva, o foco desloca-se da transação individual para a entidade — cliente, conta ou organização — enquanto unidade de análise. Trabalhos dedicados especificamente à deteção de branqueamento de capitais, como os de Doddamani et al. (2024), evidenciam que o comportamento cumulativo ao longo do tempo, expresso através de volumes, frequências, rácios e dinâmicas temporais, constitui um veículo mais robusto para a sinalização de risco do que critérios baseados apenas em montantes absolutos.

Um desafio transversal identificado nestas abordagens prende-se com o forte desequilíbrio entre classes, uma vez que os casos efetivamente associados a BC/FT representam uma fração residual do universo observado. A literatura reconhece que esta assimetria conduz facilmente a sistemas excessivamente sensíveis, com elevadas taxas de falsos positivos. Savage et al. (2016) sublinham que muitos comportamentos estatisticamente raros são, ainda assim, legítimos, defendendo que a distinção entre anomalia e ilicitude é conceptual e não meramente estatística. Ou seja, neste âmbito específico, lá porque se deteta um *outlier* não é garante que ele seja de forma alguma relevante.



Nem toda a anomalia estatística corresponde a comportamento ilícito (Savage et al., 2016).

Figura 2. 1 - Interpretação de resultados.

Esta constatação tem implicações diretas na concepção dos sistemas de detecção, sobretudo em contextos regulatórios, onde a capacidade de priorização, isto é, definir que casos devem ser avaliados primeiro, é limitada e a eficiência operacional é crítica.

Outro eixo relevante da literatura defende a importância de, no contexto do BC/FT se olhar para as relações entre entidades e para a estrutura global dessas relações, porque certos comportamentos ilícitos só são visíveis a esse nível. Estudos mais recentes exploram-no através de representações em forma de grafos, modelando relações entre contas, fluxos financeiros e entidades envolvidas. Trabalhos como os de Nguyen et al. (2024) e Wan e Li (2024) evidenciam que a incorporação destas relações pode revelar estruturas de interação compatíveis com esquemas de branqueamento mais sofisticados. Contudo, os próprios autores reconhecem que estas abordagens implicam requisitos elevados em termos de dados, infraestrutura de computação e mesmo a capacidade de interpretação, fatores que limitam a sua aplicação direta em ambientes institucionais em larga escala.

Paralelamente, vários autores salientam a importância de ser feita uma aprendizagem a partir de exemplos previamente sinalizados, particularmente em contextos onde existe acesso a dados históricos de investigações concluídas ou casos suspeitos validados. Jullum et al. (2020), num estudo aplicado a dados bancários reais de larga escala, demonstram que modelos que incorporam informação histórica rotulada apresentam ganhos significativos em termos de precisão e capacidade discriminatória, quando comparados com abordagens puramente exploratórias. Este resultado reforça mais uma vez a ideia de que o risco de BC não se manifesta apenas em desvios extremos, mas em combinações subtis de comportamentos que se repetem ao longo do tempo.

Apesar da diversidade de metodologias exploradas, a literatura científica converge em alguns pontos essenciais. Em primeiro lugar, a detecção eficaz de BC/FT exige uma visão longitudinal e agregada do comportamento financeiro, privilegiando a entidade ou agente, enquanto unidade de análise, em detrimento da transação isolada. Em segundo lugar, abordagens que não incorporam contexto e aprendizagem tendem a gerar níveis elevados de falsos positivos, comprometendo a sua utilidade operacional. Por fim, os estudos sugerem ainda que modelos capazes de aprender padrões a partir de dados reais, ainda que imperfeitos e ruidosos, oferecem um enquadramento mais promissor para a detecção de risco, sobretudo quando combinados com conhecimento de domínio e validação humana.

2.3 Abordagens da literatura no contexto do jogo online

Também na literatura acadêmica o setor do jogo e das apostas online tem sido progressivamente reconhecido como um domínio particularmente vulnerável ao risco de branqueamento de capitais e financiamento do terrorismo. Esta vulnerabilidade resulta não apenas da já referida dimensão econômica do mercado, mas sobretudo das suas características operacionais específicas, que o distinguem de outros contextos financeiros mais tradicionais. A investigação especializada identifica o jogo online como um ambiente onde a elevada frequência transacional, a liquidez quase imediata dos fundos e a natureza digital das interações criam condições favoráveis à dissimulação de fluxos financeiros ilícitos.

Levi (2009) é frequentemente citado como uma referência seminal ao sublinhar que o jogo, em particular quando operado em plataformas online e em contexto transfronteiriço, apresenta fragilidades estruturais que dificultam a monitorização eficaz. A fragmentação jurisdicional, a multiplicidade de intermediários de pagamento e a heterogeneidade dos sistemas tecnológicos reduzem a capacidade de obter uma visão integrada do comportamento do jogador, criando espaços onde práticas ilícitas podem emergir com menor probabilidade de deteção. Fatores que são reforçados pela crescente utilização de meios de pagamento eletrónicos e instrumentos financeiros digitais.

Um dos contributos centrais da literatura no domínio do jogo online reside na distinção entre comportamentos de risco do ponto de vista social ou clínico e comportamentos de risco do ponto de vista legal e regulatório. Estudos focados no jogo responsável e na identificação de jogadores problemáticos demonstram que padrões de aposta intensos, irregulares ou impulsivos podem ser estatisticamente extremos sem que tal implique, necessariamente, a prática de ilícitos financeiros. Esta distinção é fundamental, uma vez que o branqueamento de capitais pressupõe intencionalidade e objetivos específicos de ocultação ou integração de fundos, elementos que não estão presentes na maioria dos comportamentos associados ao jogo aditivo.

Neste contexto, Peres et al. (2021), num estudo desenvolvido em colaboração com o SRIJ, exploram a utilização de técnicas de análise temporal para identificar perfis distintos de jogadores online, com enfoque no jogo responsável. Os autores demonstram que é possível segmentar jogadores com base na intensidade, frequência e evolução da atividade,

identificando subconjuntos com comportamentos incomuns. Contudo, os próprios resultados evidenciam que tais métodos capturam essencialmente comportamentos atípicos, não fornecendo, por si só, critérios suficientes para distinguir entre variação legítima e comportamentos potencialmente ilícitos. Esta limitação é reconhecida implicitamente pelos autores, que enquadram os seus resultados como suporte à análise exploratória e à priorização de casos, e não como instrumentos decisórios finais.

Uma perspetiva complementar é apresentada por Hopfgartner et al. (2024), que analisam o risco associado ao jogo problemático através da modelação do comportamento histórico dos jogadores no âmbito do jogo responsável. Os autores sublinham que a identificação de situações de risco depende de uma leitura agregada e longitudinal da atividade do jogador, mas reconhecem igualmente limitações relevantes na rotulagem dos dados, frequentemente baseada em instrumentos de autoavaliação e questionários. Tal condiciona a robustez das conclusões e reforça a ideia de que padrões estatisticamente extremos podem refletir comportamentos legítimos, ainda que socialmente problemáticos, sem qualquer correspondência necessária com práticas ilícitas.

Na realidade a literatura parece reconhecer a tal ideia de que a natureza singular do jogo online e de quem o pratica, amplifica o problema dos falsos positivos. Afinal mesmo os jogadores recreativos podem apresentar picos abruptos de atividade, simplesmente associados a eventos desportivos específicos, campanhas promocionais que lhe oferecem bónus ou créditos para jogar ou na sequência de ganhos ocasionais¹⁶, produzindo padrões que se afastam da média sem qualquer intenção de dissimulação financeira.

Neste enquadramento, o trabalho de Ghaharian et al. (2023) opta por uma abordagem metodológica baseada na construção de perfis transacionais agregados ao nível dos jogadores, aplicada a dados de pagamentos. Os autores definem *payment profiles* como vetores de características extraídas da agregação histórica de transações, permitindo caracterizar regularidades comportamentais que dificilmente emergem da análise isolada de eventos pontuais. Este tipo de representação revela-se particularmente relevante no contexto do jogo online, onde a atividade do jogador se materializa através de múltiplas operações de

¹⁶ “House money effect” quando o jogador encara uma aposta ganha como dinheiro extra que, como tal, pode ser reinvestido sem risco. Ou a “hot hand fallacy”, quando o jogador acredita que a sua sorte pontual vai continuar ignorando a natureza aleatória e independente dos eventos futuros.

valor e frequência variáveis, exigindo uma leitura longitudinal do comportamento para distinguir variabilidade legítima de padrões potencialmente problemáticos.

Por fim outros estudos há, que se debruçam noutro tipo de riscos de natureza legal e regulatória no ecossistema do jogo online, nomeadamente o problema do jogo ilegal. Min e Lee (2024) abordam recentemente este problema, ao analisarem as características associadas a plataformas de jogo não autorizadas, demonstrando que determinados padrões estruturais e comportamentais permitem distinguir, em termos probabilísticos, operadores legais de operadores ilícitos. Tal como sucede noutras áreas de criminalidade financeira, os autores sublinham que a natureza clandestina do fenómeno limita o acesso a dados representativos e estáveis, constituindo um desafio estrutural à deteção e monitorização do risco.

Em conjunto, estes trabalhos evidenciam que, no domínio do jogo online, a análise do risco tende a privilegiar abordagens centradas na entidade — jogador ou plataforma — e na agregação histórica do comportamento, em detrimento da observação pontual de eventos isolados. Contudo, mostram também que os objetivos subjacentes à análise — proteção do jogador, identificação de operadores ilegais ou mitigação de riscos regulatórios — condicionam fortemente a interpretação dos padrões observados e a definição do que constitui comportamento problemático. Esta diversidade de perspetivas reforça a necessidade de distinguir claramente entre variabilidade legítima do comportamento do jogador e padrões compatíveis com práticas intencionalmente ilícitas, evitando a aplicação indiferenciada de metodologias desenvolvidas para contextos distintos.

2.4 Síntese crítica das abordagens metodológicas

A análise da literatura apresentada nos pontos anteriores evidencia uma diversidade de abordagens metodológicas aplicadas à deteção de comportamentos de risco em contextos financeiros e, em particular, no setor do jogo online. Estas abordagens podem ser organizadas, de forma sintética, em duas grandes famílias: métodos de natureza exploratória, maioritariamente não supervisionados, e modelos preditivos baseados em aprendizagem supervisionada.

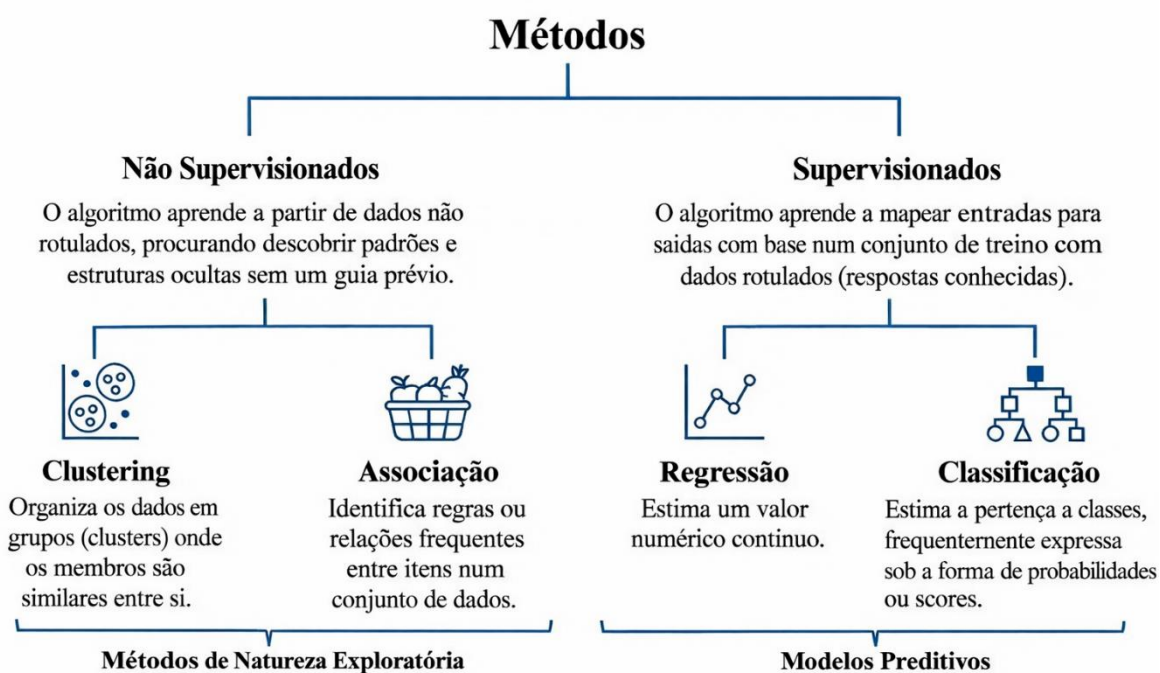


Figura 2. 2 - Métodos não supervisionados (exploratórios) vs. supervisionados (preditivos).

Os métodos não supervisionados surgem frequentemente como ponto de partida nos estudos analisados. Trabalhos como o de Peres et al. (2021), aplicado ao contexto do jogo online, recorrem a técnicas de *clustering* de séries temporais com o objetivo de identificar perfis comportamentais distintos e padrões de atividade incomuns. De forma semelhante, na literatura mais geral sobre branqueamento de capitais, abordagens exploratórias baseadas em deteção de *outliers* ou segmentação de entidades são utilizadas para compreender a estrutura dos dados e revelar comportamentos que se afastam da “norma” estatística. Estas metodologias apresentam vantagens claras numa fase inicial de análise, permitindo explorar grandes volumes de dados sem necessidade de rotulagem prévia, bem como apoiar processos de triagem ou definição de prioridades.

Os trabalhos e estudos académicos nestes campos parecem ser consistentes ao reconhecer que as abordagens exploratórias apresentam limitações relevantes quando o objetivo ultrapassa a mera identificação de comportamentos atípicos e passa a centrar-se no apoio à decisão, seja ela investigatória, alarmística ou regulatória. A principal limitação prende-se com a incapacidade de distinguir, de forma sistemática, entre variabilidade legítima e

comportamentos efetivamente ilícitos, conduzindo frequentemente a taxas elevadas de falsos positivos. Este aspeto é particularmente crítico em domínios como o jogo online, onde a heterogeneidade natural do comportamento dos jogadores é elevada.

Em resposta a estas limitações, um número crescente de trabalhos privilegia modelos de aprendizagem supervisionada, formulando a deteção de risco como uma tarefa de classificação binária ou de atribuição de um *score* de risco (pontuação de risco). Trabalhos como os de Doddamani et al. (2024) e Jullum et al. (2020), no contexto do branqueamento de capitais, demonstram que a aprendizagem a partir de exemplos previamente sinalizados permite capturar combinações subtis de características comportamentais, frequentemente associadas a interações complexas entre variáveis, que dificilmente seriam identificadas através de critérios unidimensionais ou de simples desvios estatísticos.

Estes estudos recorrem a modelos de aprendizagem supervisionada baseados em árvores de decisão e métodos de *ensemble*, como a regressão logística “penalizada”, técnicas de *boosting* e variantes como o XGBoost, evidenciando o potencial desta família de algoritmos na deteção de padrões ilícitos. De forma análoga, no domínio do jogo online, Hopfgartner et al. (2024) aplicam modelos supervisionados de natureza preditiva para a identificação de comportamentos de risco associados ao jogo responsável, evidenciando ganhos claros em termos de capacidade discriminatória face a abordagens puramente exploratórias. Min e Lee (2024), por sua vez, recorrem igualmente a técnicas supervisionadas na deteção de jogo ilegal, enfrentando desafios metodológicos semelhantes aos do BC/FT, nomeadamente a escassez de casos positivos e o forte desequilíbrio entre classes.

Para além das abordagens exploratórias e dos modelos supervisionados baseados em atributos agregados, parte da literatura recente explora metodologias consideradas mais avançadas, em particular representações baseadas em grafos e técnicas de aprendizagem automática aplicadas a dados relacionais. Estudos como os de Nguyen et al. (2024) e Wan e Li (2024) apresentam propostas de modelação dos sistemas financeiros como redes de entidades interligadas por fluxos transacionais, extraíndo representações vetoriais dos nós (*graph embeddings*) que codificam relações estruturais e padrões comunitários. Estas representações são posteriormente utilizadas por classificadores supervisionados, como o Random Forest (Nguyen et al., 2024) ou Redes Neurais (Wan & Li, 2024), permitindo capturar padrões coletivos que não são observáveis a partir de atributos individuais isolados.

Esta leitura é reforçada por trabalhos de natureza mais abrangente, como o de Fan et al. (2025), que realizam uma revisão aprofundada das abordagens de aprendizagem profunda aplicadas à detecção de branqueamento de capitais. Os autores sublinham o potencial destas técnicas para lidar com padrões complexos e dados de elevada dimensionalidade, mas salientam simultaneamente desafios estruturais relevantes, nomeadamente ao nível da privacidade, da disponibilidade limitada de dados rotulados e da integração em ambientes regulatórios reais.

Contudo, os próprios autores reconhecem limitações relevantes à adoção destas abordagens em contextos institucionais. A construção de representações relacionais exige dados completos e consistentes, frequentemente indisponíveis ou fragmentados, sobretudo em ambientes regulatórios com múltiplos operadores e jurisdições. Acresce ainda a elevada complexidade computacional e a extrema dificuldade de interpretar os modelos resultantes, fatores que dificultam a sua validação operacional e jurídica. Em consequência, apesar do seu interesse académico, estas metodologias surgem sobretudo como complementares, e não como soluções centrais, nos sistemas de detecção de risco atualmente implementados.

CAPÍTULO 3. MONITORIZAÇÃO DE TRANSAÇÕES E AVALIAÇÃO DO RISCO DE BC/FT

3.1 Dados

O conjunto de dados utilizados é constituído por registos das transações financeiras realizadas nas contas de jogador nas entidades exploradoras de jogos e apostas online. Cada linha corresponde a uma operação (registo) individual na respetiva conta, isto é, representa um depósito, um levantamento ou uma regularização, registados ao nível do jogador, num determinado instante.

Toda esta informação foi extraída dos reportes remetidos diariamente ao SRIJ, em formato *Extensible Markup Language* (XML), obedecendo às previsões do Regulamento (técnico) n.º 903-B/2015, que aprovou o Regulamento dos Requisitos do Sistema Técnico do Jogo Online¹⁷.

No âmbito do sistema de reporte, estes dados são continuamente integrados na denominada infraestrutura de controlo do SRIJ, em campos específicos destinados à monitorização das contas de jogador e dos fluxos financeiros associados. Atendendo à natureza eminentemente técnica e regulatória desta descrição, remete-se o leitor interessado para o texto do referido regulamento técnico, onde se encontra detalhado o modelo de dados e as regras de mapeamento entre o sistema técnico das entidades exploradoras e a infraestrutura de controlo.

Para cada operação, encontram-se disponíveis as seguintes variáveis principais: um identificador numérico anónimo do jogador (ID_CNTJOG), um código do tipo de operação (ID_OPTRCNT), a data e hora em formato de *timestamp* com indicação do fuso horário (TIMESTP_OP), o saldo disponível imediatamente antes da operação em causa (SALDO_INI), o montante movimentado (SALDO_MOV) e o saldo posterior à operação (SALDO_FIM).

¹⁷ Em particular, as operações aqui analisadas correspondem aos elementos previstos no *schema* TRAN_, cujas regras de mapeamento se encontram descritas no ponto V.5 do referido regulamento, na página 37588-(34).

Tabela 3. 1 - Variáveis.

Variável	Descrição	Tipo	Exemplo
ID_CNTJOG	Identificador anonimizado da conta de jogador	Inteiro	1601808921
ID_OTRCNT	Código do tipo de operação (10, 11, 90, 91)	Catégorica nominal	10
TIMESTP_OP	Timestamp da operação (hora de Lisboa)	Data-hora	2025.11.25 19:53:43,000000000 EUROPE/LISBON
SALDO_INI	Saldo disponível antes da operação	Númerica contínua	3.45
SALDO_MOV	Montante movimentado (depósito, levantamento ou regularização)	Númerica contínua	10.00
SALDO_FIM	Saldo da conta após a operação	Númerica contínua	13.45

O tipo de operação é codificado numericamente, representando uma determinada operação. O código 10 corresponde a depósitos na conta de jogador, isto é, operações em que o jogador provisiona a sua conta de jogo a partir de um instrumento financeiro. O código 90 identifica levantamentos da conta de jogador, em que o saldo disponível é transferido para a conta de pagamento (por exemplo, conta bancária) titulada pelo jogador. Marginalmente são ainda identificadas operações com o código 11, representando uma regularização a crédito – entre outros, quando um pedido de levantamento por motivo superveniente não é concretizado e o montante estorna à conta de jogador (volta a ser creditado). E por fim, o código 91 correspondendo a regularizações a débito, designadamente situações em que a conta de jogador foi indevidamente creditada e o montante é subsequentemente debitado.

O estudo parte de dois subconjuntos de dados. O primeiro corresponde à informação respeitante a um conjunto de jogadores já previamente identificados como potenciais casos de branqueamento de capitais, ainda que com diferentes graus de suspeição¹⁸, a que chamaremos “casos positivos” ou conjunto dos casos positivos. Este integra 17 590 operações, distribuídas por 100 jogadores distintos. Já o segundo conjunto consiste numa amostra aleatória simples (doravante amostra ou amostra de referência), de 15 074 diferentes jogadores, selecionados a partir da base de dados operacional, para os quais se assume, em regra, a inexistência de sinais prévios de BC, embora se admita a possibilidade de existirem entre eles, casos não detetados. Esta amostra contém 1 026 162 operações no total. A coexistência destes dois conjuntos permite abordar o problema como uma tarefa de classificação supervisionada, em que a classe positiva é definida pelos jogadores já

¹⁸ Consequência de diferentes tipologias de ilícitos praticados ou das diferentes fases em que se encontra o processo.

previamente sinalizados e a classe negativa pela população de referência; reconhecendo-se, contudo, a possibilidade de ruído na rotulagem da classe negativa, algo mais ou menos previsível e esperado para a deteção de ilícitos.

Em termos de confidencialidade, importa enfatizar que todos os dados utilizados são reais e correspondem a transações efetivamente realizadas e registadas nos sistemas técnicos dos operadores e reportadas posteriormente à infraestrutura de controlo do SRIJ. Os identificadores das contas de jogador associadas, fornecidos pelo autor, já se encontravam anonimizados na origem, sendo virtualmente impossível para alguém externo ao sistema conseguir identificar a quem pertenciam. Ainda assim, foi aplicada uma camada adicional de proteção, através de um algoritmo de transformação conhecido apenas pelo próprio, com o objetivo de reforçar a confidencialidade dos dados, atendendo à extrema sensibilidade do tema e à natureza regulatória da informação. Esta opção reflete uma escolha deliberada de trabalhar com dados reais, em vez de dados simulados. Embora a utilização de dados simulados facilitasse algumas dimensões de exposição, as conclusões resultariam, nesse caso, sobretudo da aplicação formal de técnicas estatísticas a um cenário teórico, logo com menor significado empírico. O recurso a dados reais, ainda que anonimizados, permite que os padrões identificados e os resultados do modelo tenham interpretação concreta no contexto do jogo online regulado.

Do ponto de vista transaccional, observa-se uma predominância de operações de depósito em ambos os conjuntos, o que é consistente com a própria natureza dos jogos de fortuna ou azar, nos quais, em abstrato, se perde mais do que se ganha.

Tabela 3. 2 - Número de operações por tipo de código de operação.

Código	Descrição	Casos positivos	Amostra
10	Depósitos	13889	840541
11	Regularizações a crédito	0	17
90	Levantamentos	3701	185589
91	Regularizações a débito	0	15
Total		17590	1026162

No conjunto dos casos positivos, existem 13 889 depósitos (código 10) e 3 701 levantamentos (código 90), não surgindo operações de regularização. Já na amostra de referência, observam-se 840 541 depósitos, 185 589 levantamentos, 15 regularizações a débito (código 91) e 17 regularizações a crédito (código 11), refletindo a existência de um volume muito residual de ajustes de saldo face ao total de operações.

Os montantes movimentados (SALDO_MOV) são variáveis contínuas, expressas em unidades monetárias, apresentando, em ambos os conjuntos, forte assimetria à direita e caudas pesadas, como aliás é típico em dados financeiros (Cont, 2001, p. 226).

Na escala original dos dados, esta assimetria traduz-se numa grande concentração de operações de baixo valor e numa presença relevante de valores extremos, o que “comprime” a leitura da zona central e dificulta a comparação direta entre grupos.

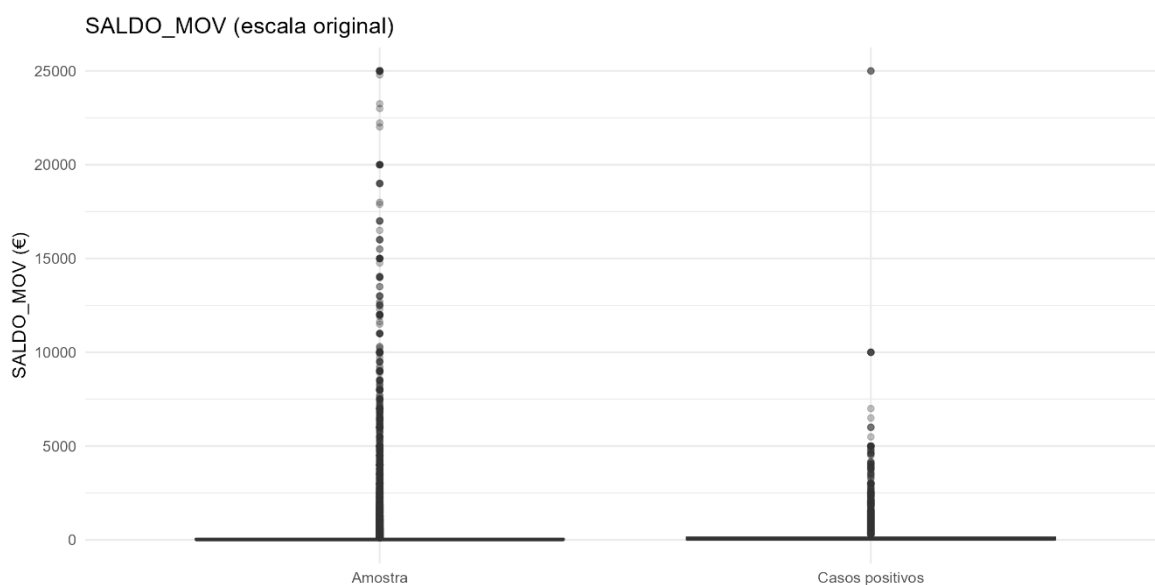


Figura 3. 1 - Boxplot do SALDO_MOV (escala original).

Com o auxílio de uma transformação logarítmica é fácil constatar que a curva associada aos casos positivos se encontra deslocada para a direita, indicando que estes jogadores realizam, em média, operações de valor superior às observadas na amostra dita de referência. Além disso, a cauda direita é mais espessa nos casos positivos, evidenciando uma maior frequência de operações de valor elevado. Em ambos os grupos, verifica-se uma marcada assimetria à direita, característica.

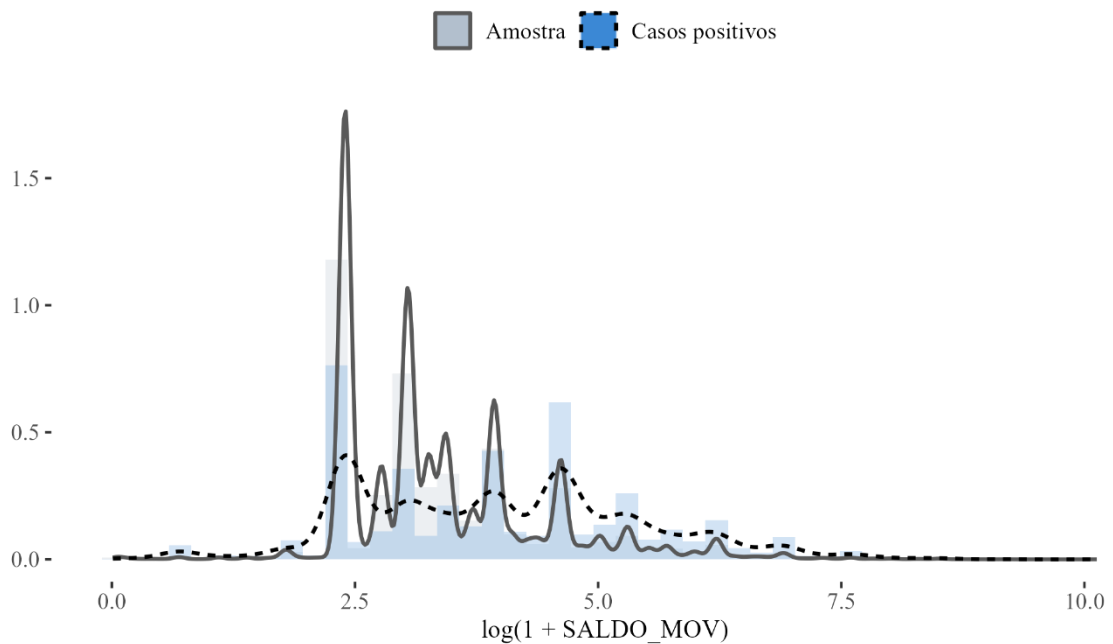


Figura 3. 2 - Distribuição do SALDO_MOV, em escala logarítmica, com histogramas normalizados e curva empírica sobreposta.

Nos “casos positivos”, os montantes, expressos em euros, variam aproximadamente entre 0,01 e 25 000, com uma mediana em torno de 50, uma média próxima de 170 e um desvio padrão da ordem de 536. Os quantis superiores evidenciam a presença de operações de valor elevado: o percentil 90 situa-se em cerca de 400 e o percentil 99 em torno de 2 000. Já na amostra de referência, os montantes apresentam o mesmo intervalo teórico (entre 0,01 e 25 000), mas com níveis médios significativamente inferiores: a mediana é de cerca de 20, a média em torno de 72 e o desvio padrão aproximadamente 325. Os quantis superiores revelam igualmente caudas longas, com um percentil 90 na ordem de 105 e um percentil 99 próximo de 860. Em termos gerais, o conjunto dos casos positivos exhibe operações de montante mais elevado, em média, do que a amostra de referência, ainda que com grande variabilidade em ambos os grupos.

Tabela 3. 3 - Estatísticas descritivas do SALDO_MOV.

Estatística	Casos positivos	Amostra
Mínimo	0.01	0.01
Mediana	50.00	20.00
Média (\bar{x})	169.77	72.30
Desvio padrão (s)	536.41	324.60
Percentil 25	15.00	10.00
Percentil 75	132.35	50.00
Percentil 90	400.00	105.10
Percentil 99	2000.00	859.39
Máximo	25000.00	25000.00

Ao nível do jogador, a distribuição do número de operações por conta é bastante heterogénea, com uma distribuição com cauda direita pronunciada e uma maior concentração de jogadores com elevada atividade transaccional no conjunto dos “casos positivos”.

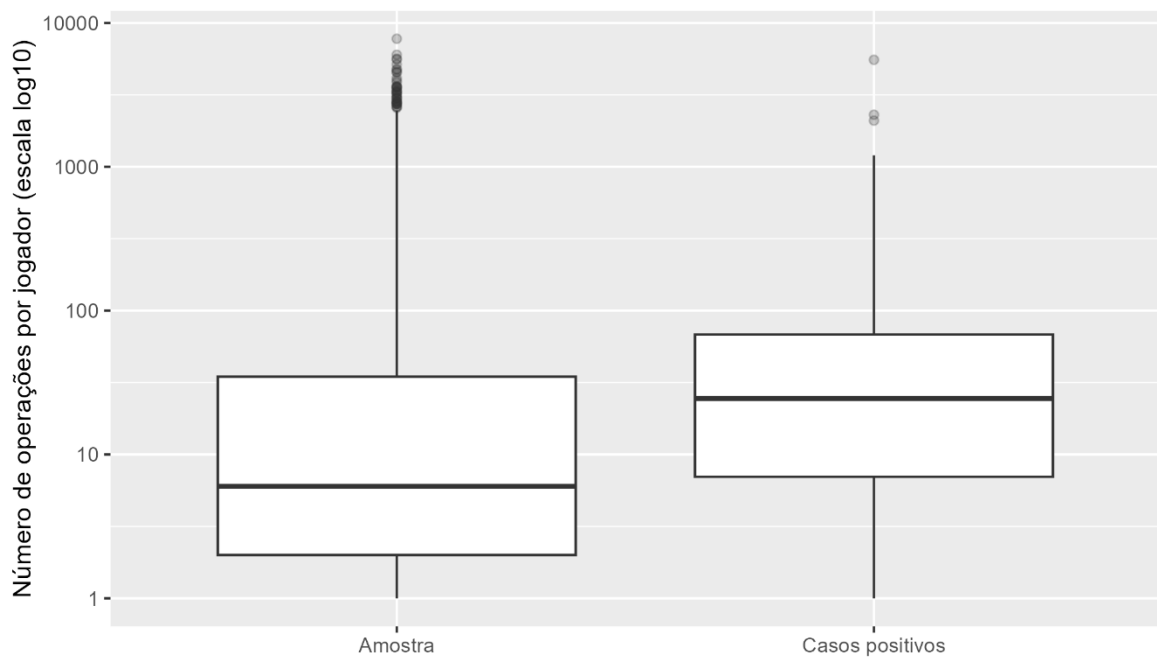


Figura 3. 3 - Número de operações por jogador (escala logarítmica), por grupo.

Nestes, o número de operações por jogador varia entre 1 e mais de 5 500, com uma mediana em torno de 25 operações, uma média próxima de 176, um percentil 90 de cerca de 214 e um percentil 99 superior a 2 300. Na amostra de referência, o número de operações por jogador varia igualmente entre 1 e vários milhares, mas com uma concentração mais forte em séries curtas: a mediana é de aproximadamente 6 operações, a média ronda 68, o percentil 90 situa-se próximo de 149 e o percentil 99 perto da marca das 990 operações. Esta comparação sugere que, em média, os jogadores incluídos no conjunto positivo evidenciam uma atividade transacional mais intensa ao longo do período de observação.

Tabela 3. 4 - Número de operações por jogador.

Estatística	Casos positivos	Amostra
Mínimo	1.00	1.00
Mediana	24.50	6.00
Média (\bar{x})	175.90	68.07
Percentil 90	213.60	149.00
Percentil 99	2333.44	988.54
Máximo	5545.00	7768.00

Já quanto à extensão temporal da atividade de cada jogador, a mesma é quantificada pela diferença (em dias) entre o primeiro e o último registo de operação disponíveis, ou seja, corresponde ao intervalo de dias entre a primeira transação e a última de cada jogador.

Tabela 3. 5 - Atividade contínua do jogador, em dias.

Estatística	Casos positivos	Amostra
Mínimo	0.00	0.00
Mediana	31.39	27.69
Média (\bar{x})	315.16	105.65
Percentil 75	611.88	215.79
Percentil 90	1078.52	331.54
Percentil 99	1400.71	364.20
Máximo	1470.54	364.99

No conjunto dos casos positivos, o intervalo de atividade varia entre episódios pontuais (com duração praticamente nula¹⁹) e históricos superiores a quatro anos. A mediana deste intervalo é de cerca de 31 dias, a média aproxima-se de 315 dias, e os percentis 75, 90 e 99 situam-se aproximadamente em 612, 1 079 e 1 401 dias, respetivamente. Na amostra de referência, a duração das séries é, em média, mais curta: a mediana ronda os 28 dias, a média é de cerca de 106 dias, o percentil 75 localiza-se próximo de 216 dias e o percentil 99 em torno de 364 dias. No entanto, para este ponto há uma justificação óbvia e que importa desde logo transmitir. Os casos positivos, uma vez detetados, são alimentados com séries temporais históricas, contendo, sempre que possível, toda a atividade passada, tornando-as assim tão extensas quanto possível, por forma a maximizar a robustez analítica e a apoiar a instrução dos correspondentes inquéritos de investigação.

3.2 Metodologia

A abordagem metodológica seguida neste trabalho enquadra-se, em termos gerais, num ciclo clássico de *data science*²⁰, articulando as fases de compreensão do negócio, de compreensão dos dados, de preparação dos mesmos, de modelação, de avaliação e de interpretação dos

¹⁹ O valor mínimo de 0,00 decorre do arredondamento da duração em dias; valores efetivamente nulos foram excluídos por traduzirem ausência de atividade observável.

²⁰ Também conhecido como CRISP-DM (*Cross-Industry Standard Process for Data Mining*).

resultados. De forma simplificada, o objetivo consiste em construir um modelo estatístico que, com base no histórico de operações de cada jogador, estime a probabilidade de este integrar o conjunto dos “casos positivos”, isto é, de evidenciar padrões de risco compatíveis com comportamentos potencialmente relacionados com o branqueamento de capitais e o financiamento do terrorismo.

Como se aprendeu pela literatura, a unidade de análise adotada é um elemento, no caso o jogador (identificado por ID_CNTJOG) e não a operação individual. O conjunto original encontra-se em formato longo (uma linha por operação). Após agregação por jogador, obtém-se uma tabela ao nível do jogador (uma linha por jogador), que constitui a base de dados para a modelação. Cada jogador é caracterizado por um conjunto de variáveis derivadas que sintetizam o seu comportamento transacional ao longo do período de observação, nomeadamente o número de depósitos e levantamentos, os volumes totais movimentados, os rácios entre entradas e saídas, medidas de dispersão e de concentração temporal, bem como indicadores de intensidade, relativo à frequência ou volume de atividade por unidade de tempo, e de volatilidade, traduzindo a variabilidade dos montantes movimentados ao longo do histórico observado, entre outros. Acresce que a dimensão temporal é incorporada por indicadores agregados (p. ex., duração), não se procedendo à modelação sequencial completa das séries.

Estas variáveis organizam-se em cinco dimensões, nas variáveis de frequência (*n_ops*, *n_dep*, *n_wdr*), volume (*vol_dep*, *vol_wdr*, *vol_tot*), intensidade temporal (*active_days*, *ops_per_day*), relação entre entradas e saídas (*ratio_wdr_dep*) e distribuição dos montantes movimentados (*mov_mean*, *mov_median*, *mov_sd*, *mov_max*, *mov_p90*, *mov_p99*).

Tabela 3. 6 - Variáveis agregadas ao nível do jogador.

Variável	Descrição	Dimensão	Exemplo
n_ops	Número total de operações observadas	Frequência	8
n_dep	Número total de depósitos	Frequência	6
n_wdr	Número total de levantamentos	Frequência	2
vol_dep	Montante total depositado	Volume	410.00
vol_wdr	Montante total levantado	Volume	330.00
vol_tot	Montante total movimentado	Volume	740.00
ratio_wdr_dep	Rácio entre o montante levantado e o montante depositado	Relação entradas/saídas	0.80
active_days	Duração da atividade observada, em dias	Intensidade temporal	43.00
ops_per_day	Número médio de operações por dia de atividade	Intensidade temporal	0.19
mov_mean	Média dos montantes movimentados por operação	Distribuição dos montantes	92.50
mov_median	Mediana dos montantes movimentados por operação	Distribuição dos montantes	40.00
mov_sd	Desvio-padrão dos montantes movimentados	Distribuição dos montantes	71.30
mov_max	Maior montante movimentado numa única operação	Distribuição dos montantes	200.00
mov_p90	Percentil 90 dos montantes movimentados	Distribuição dos montantes	186.00
mov_p99	Percentil 99 dos montantes movimentados	Distribuição dos montantes	198.60

Daqui resulta que a informação originalmente registada ao nível de cada operação é agregada ao nível de conta de jogador, permitindo formular o problema como uma tarefa de classificação supervisionada binária, em que a variável de resposta toma o valor 1 para os casos positivos e 0 para os restantes jogadores da amostra de referência.

Como consequência do enquadramento operacional em que os dados são recolhidos e utilizados, verifica-se uma diferença relevante na extensão temporal dos registos disponíveis por jogador. As séries associadas aos “casos positivos” cobrem, em muitos casos, períodos plurianuais, enquanto a “amostra de referência” foi restringida aos últimos doze meses. Esta assimetria decorre do contexto operacional em que os dados tratados: uma vez detetado um caso suspeito, procede-se à recuperação, para efeitos probatórios e de instrução de inquérito, de toda a atividade histórica disponível da conta do jogador; ao passo que a monitorização

prospetiva do risco é, por natureza, centrada no curto prazo, sendo raramente necessário recuar mais de um ano para identificar padrões relevantes.

Do ponto de vista estatístico, a modelação não explora explicitamente a ordem sequencial dos eventos, recorrendo antes a variáveis agregadas que resumem o comportamento transaccional de cada jogador. Assim, a diferença na extensão das séries não compromete diretamente o processo de aprendizagem e poderá, no máximo, ser encarada como uma limitação metodológica a considerar no momento da leitura dos resultados.

A preparação dos dados envolve várias etapas: (i) verificação de consistência dos registos (incluindo tipos de dados e eliminação de duplicados); (ii) definição da janela temporal efetiva por jogador; (iii) construção das variáveis agregadas de interesse; (iv) tratamento de valores em falta, quando existam; e (v) eventual transformação de variáveis fortemente assimétricas, técnica que é frequentemente utilizada, como já se referiu antes, para dados financeiros. Neste domínio, a presença de caudas pesadas não é encarada como um erro a corrigir, mas como uma característica estrutural do fenómeno; assim, privilegia-se a aplicação de transformações estabilizadoras de variância, em detrimento da eliminação de observações extremas, uma vez que estas podem conter informação relevante para a sinalização de padrões de risco, incluindo comportamentos potencialmente ilícitos.

Dado o forte desequilíbrio entre classes (cerca de uma centena de “casos positivos” face a mais de quinze mil jogadores na “amostra de referência”) e a possibilidade de a classe negativa conter algum ruído de rotulagem²¹, opta-se por recorrer a métodos de classificação supervisionada robustos a desequilíbrios e a relações não lineares entre variáveis. Em particular, o modelo principal adotado neste trabalho será um Random Forest, atendendo à sua capacidade de lidar com variáveis heterogéneas, capturar interações complexas, reduzir o risco de sobreajustamento através da agregação de múltiplas árvores e fornecer medidas internas de importância das variáveis, aspetos amplamente documentados na literatura (Breiman, 2001; Hastie et al., 2009; James et al., 2021).

Outro dos problemas que advém deste forte desequilíbrio é a sua influência na escolha do limiar de decisão. Esta não pode ser arbitrária e depende do compromisso entre a deteção de

²¹ A presença de observações cuja classe atribuída não corresponde necessariamente à realidade subjacente, situação comum em problemas de deteção de ilícitos, onde apenas uma fração dos casos é efetivamente conhecida.

casos relevantes e o controlo do número de sinalizações indevidas. A literatura sublinha que, quando os custos associados a não detetar um caso potencialmente ilícito são elevados, é razoável optar por limiares mais conservadores (Fawcett, 2006; Elkan, 2001; Hastie et al., 2009).

Importa também justificar a não adoção de modelos de séries temporais baseados em redes neuronais recorrentes (como LSTM ou GRU). A estes modelos recomenda-se a existência de sequências ordenadas de comprimento uniforme, grandes volumes de dados e a preservação da estrutura temporal completa, isto é, regularidade na observação e dependência temporal entre eventos consecutivos, características típicas da modelação de séries temporais. Tais pressupostos não se verificam neste contexto: as séries associadas a cada jogador são irregulares, de extensão muito variável e, no caso dos “casos positivos”, frequentemente plurianuais. Além disso, o objetivo deste estudo não é prever a ocorrência da próxima operação, mas sim caracterizar o perfil agregado de comportamento de cada jogador, ou seja, por outras palavras, identificar o tipo de jogador em análise, o que torna a adoção deste tipo de modelos, salvo melhor opinião, conceptualmente e operacionalmente inadequada.

Para efeitos de comparação e controlo, foram considerados modelos alternativos, nomeadamente regressões logísticas penalizadas e outros modelos baseados em árvores, como métodos de *gradient boosting*. Contudo, atendendo ao foco do estudo e à adequação do Random Forest ao problema em análise, esses modelos não são explorados em detalhe nos resultados, privilegiando-se uma análise aprofundada do Random Forest.

A exploração sistemática de arquiteturas alternativas, incluindo métodos de *gradient boosting* mais avançados e modelos de *deep learning* sequencial, é deixada como sugestão para trabalho futuro, caso venham a estar disponíveis séries temporais mais homogéneas e um volume substancialmente maior de casos positivos.

O treino do modelo será realizado com um conjunto de treino estratificado, mantendo-se um conjunto de teste independente para avaliação externa. A validação será efetuada através de validação cruzada estratificada, de modo a assegurar a estabilidade estatística das métricas. A avaliação do desempenho não se limitará à taxa global de acerto, pouco informativa em contextos de classes raras; recorrer-se-á a métricas mais adequadas à deteção de ilícitos,

como a sensibilidade (*recall*), a precisão (*precision*), a medida F1, a área sob a curva ROC (AUC-ROC) e a área sob a curva precisão–revocação (AUC-PR).

Todo o trabalho empírico foi desenvolvido em R (R Core Team, 2025), recorrendo a pacotes amplamente utilizados na literatura de ciência de dados e aprendizagem automática. Em particular, utilizou-se o *tidyverse* para preparação, transformação e exploração dos dados (Wickham et al., 2019), o *rsample* para validação cruzada estratificada (Frick et al., 2026), o *ranger* para implementação do modelo Random Forest (Wright & Ziegler, 2017), o *yardstick* para cálculo de métricas de desempenho (Kuhn et al., 2026), e os pacotes *pROC* e *PRROC* para análise das curvas ROC e precisão–revocação (Robin et al., 2011; Grau et al., 2015).

As escolhas metodológicas e de modelação foram orientadas por referências clássicas da literatura, em particular por James et al. (2021), bem como pela documentação oficial dos pacotes utilizados e por materiais pedagógicos de apoio, utilizados como fonte de inspiração para boas práticas de implementação. Esta abordagem assegura reprodutibilidade, transparência e possibilidade de evolução futura do modelo.

Por fim, atendendo à riqueza dos dados e à multiplicidade de abordagens possíveis para a análise do comportamento transacional e para a interpretação dos modelos de aprendizagem automática, optou-se por concentrar o corpo principal do trabalho, apenas nos resultados essenciais à avaliação do desempenho e à discussão do modelo proposto. Análises exploratórias adicionais, representações gráficas complementares e leituras alternativas das variáveis e do modelo são apresentadas em anexo, como forma de ilustrar outras perspetivas possíveis, sem desvirtuar o foco central do que se está a estudar.

3.2.1 Exemplo ilustrativo de agregação ao nível do jogador

O conjunto de dados original encontra-se, tal como indicado, em formato longo, isto é, uma linha por operação (depósito, levantamento ou regularização), identificada pelo jogador (ID_CNTJOG) e por um *timestamp* (TIMESTP_OP), contendo ainda o montante movimentado (SALDO_MOV), entre outras variáveis, nomeadamente aquelas que se relacionam com este, como o saldo inicial (SALDO_INI) e final (SALDO_FIM), antes e após a operação.

Contudo, o objetivo que se pretende não é classificar operações isoladas, mas sim avaliar o risco ao nível do jogador. Assim, para efeitos de modelação, cada jogador é representado por um vetor de características agregadas que sintetiza o seu comportamento transacional no período observado. Em termos práticos, passa-se de uma tabela em formato longo, com N_{tot} operações (uma linha por operação), para uma tabela ao nível do jogador, com n jogadores (uma linha por jogador), em que cada coluna corresponde a uma estatística agregada.

Considere-se, a título meramente ilustrativo, um jogador i com 8 operações no período observado:

- Realizou 6 depósitos (código 10): 50€, 20€, 100€, 30€, 200€, 10€;
- Procedeu a 2 levantamentos (código 90): 150€, 180€;
- A primeira operação foi realizada a 01/02 e última a 15/03.

A partir destas operações podem construir-se variáveis agregadas que sintetizam o comportamento transacional do jogador:

n_{ops} : número total de operações (= 8)

n_{dep} : número de depósitos (= 6)

n_{wdr} : número de levantamentos (= 2)

vol_{dep} : total depositado (= 410€)

vol_{wdr} : total levantado (= 330€)

$ratio_{wdr_{dep}}$: rácio levantamentos/depósitos (= $330/410 \approx 0,80$)

$active_{days}$: duração da atividade (= dias entre a primeira e a última operação)

Deste modo, o jogador deixa de ser representado por 8 linhas (uma por operação) e passa a ser representado por uma única linha $x_i = (x_{i1}, \dots, x_{ip})$, isto é, um vetor de características (perfil) utilizado na modelação, do tipo:

$$\left(n_{ops}, n_{dep}, n_{wdr}, vol_{dep}, vol_{wdr}, ratio_{wdr_{dep}}, active_{days} \right) \quad (3.1)$$

Ou de forma mais formal, para cada jogador i

Seja $\{(OP_{it}, SALDO_MOV_{it}, TIMESTP_OP_{it})\}_{t=1}^{N_i}$ o conjunto de operações observadas, onde OP_{it} indica o tipo de operação.

Definem-se então variáveis agregadas que passam a constituir componentes do vetor x_i . Por exemplo:

$$x_{i1} = n_{\text{ops},i} = \sum_{t=1}^{N_i} 1,$$

$$x_{i2} = n_{\text{dep},i} = \sum_{t=1}^{N_i} \mathbb{1}(OP_{it} = 10),$$

$$x_{i3} = n_{\text{wdr},i} = \sum_{t=1}^{N_i} \mathbb{1}(OP_{it} = 90),$$

$$x_{i4} = \text{vol}_{\text{dep},i} = \sum_{t:OP_{it}=10} \text{SALDO_MOV}_{it},$$

$$x_{i5} = \text{vol}_{\text{wdr},i} = \sum_{t:OP_{it}=90} \text{SALDO_MOV}_{it},$$

$$x_{i6} = \text{ratio}_{\text{wdr/dep},i} = \frac{\text{vol}_{\text{wdr},i}}{\text{vol}_{\text{dep},i} + \varepsilon},$$

$$x_{i7} = \text{active_days}_i = \frac{\max_t(\text{TIMESTP_OP}_{it}) - \min_t(\text{TIMESTP_OP}_{it})}{1 \text{ dia}},$$

onde $\mathbb{1}(\cdot)$ é a função indicadora e $\varepsilon > 0$ é um termo pequeno que evita divisão por zero quando $\text{vol}_{\text{dep},i} = 0$. Assim, cada jogador i é representado por um vetor $x_i \in \mathbb{R}^p$ (uma linha na matriz \mathbf{X}), em vez de por uma sequência de operações em formato longo.

Importa por fim sublinhar que, a dimensão temporal é sempre incorporada através de indicadores agregados, como a duração e intensidade, não se procedendo à modelação sequencial completa das séries (isto é, não se modela pela ordem exata das operações). Esta opção permite comparar jogadores com históricos de comprimentos diferentes e focar a análise em padrões globais de comportamento financeiro.

3.3 Fundamentos dos modelos de árvore e Random Forest

O modelo adotado neste trabalho insere-se na classe dos métodos de aprendizagem supervisionada aplicados a problemas de classificação binária. Seguindo a notação estabelecida por Hastie et al. (2009)²², considera-se um conjunto de dados de treino constituído por n observações independentes,

²² Sem prejuízo da referência à obra original, onde é utilizada a notação N , optou-se no presente texto pela grafia n para designar a dimensão do conjunto de treino, em conformidade com a convenção estatística usual para dimensões amostrais.

$$\mathcal{T} = \{(x_i, y_i)\}_{i=1}^n, \quad (3.2)$$

onde

$x_i = (x_{i1}, \dots, x_{ip}) \in \mathbb{R}^p$ representa o vetor p de variáveis explicativas agregadas associadas ao jogador i , e

$y_i \in \{0,1\}$ indica a classe observada, correspondendo respectivamente a jogador não sinalizado e a jogador identificado como “caso positivo”.

Fazendo um paralelismo, x_i resulta da agregação das operações do jogador i num vetor de características, n corresponde ao número de jogadores (observações) no conjunto de treino, enquanto N_i denota o número de operações observadas para o jogador i (cf. Capítulo 3.2.1).

De forma matricial, as variáveis explicativas podem ser organizadas numa matriz de dados

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix} \in \mathbb{R}^{n \times p}, \quad (3.3)$$

onde cada linha corresponde a um jogador e cada coluna a uma variável explicativa agregada. O vetor de respostas é dado por

$$\mathbf{y} = (y_1, \dots, y_n)^\top \in \{0,1\}^n. \quad (3.4)$$

Neste enquadramento, o conjunto de treino pode ser representado de forma compacta pelo par (\mathbf{X}, \mathbf{y}) .

O objetivo da aprendizagem consiste em estimar uma função de decisão

$$f: \mathbb{R}^p \rightarrow \{0,1\}, \quad (3.5)$$

ou, de forma mais geral, uma função probabilística

$$\hat{P}(Y = 1 \mid X = x), \quad (3.6)$$

que permita classificar novos jogadores com base no seu perfil comportamental agregado.

3.3.1 Árvores de decisão e o método CART

As árvores de decisão constituem o bloco elementar sobre o qual assentam os modelos Random Forest.

No enquadramento clássico do método CART (*Classification and Regression Trees*)²³, introduzido por Breiman et al. (1984) e que se pode encontrar sistematizado em Hastie et al. (2009), o espaço das variáveis explicativas é particionado de forma recursiva através de divisões binárias do tipo $x_j \leq s$ ou $x_j > s$, onde x_j representa uma variável explicativa e s um ponto de corte.

Por exemplo, numa variável agregada como o volume total depositado ($x_j = vol_dep$), uma divisão do tipo $x_j \leq s$ pode corresponder a “ $vol_dep \leq 1000€$ ”, separando jogadores com menor e maior intensidade financeira. De forma análoga, poderiam considerar-se cortes em variáveis como o número de operações (n_ops) ou a duração da atividade ($active_days$).

Cada divisão origina dois nós descendentes, sendo o processo repetido sucessivamente até que se atinja um critério de paragem, como um número mínimo de observações por nó ou a ausência de ganho adicional em termos de homogeneidade. O resultado é uma estrutura hierárquica composta por nós internos e nós terminais (folhas), que induz uma partição do espaço amostral em regiões disjuntas R_1, \dots, R_M , às quais se associam previsões constantes.

No contexto da classificação binária²⁴, a previsão atribuída a uma folha pode ser interpretada como a classe dominante nesse nó ou, de forma probabilística, como a proporção estimada de observações pertencentes à classe positiva. Seja p_m essa proporção no nó m . A qualidade (ou homogeneidade) de um nó é avaliada através de uma função de impureza, sendo duas das medidas mais utilizadas o índice de Gini,

$$G(p_m) = 2p_m(1 - p_m), \quad (3.7)$$

e a entropia,

$$H(p_m) = -p_m \log(p_m) - (1 - p_m) \log(1 - p_m). \quad (3.8)$$

²³ Como o acrónimo sugere, é um método proposto para problemas de classificação e regressão, baseado na partição recursiva do espaço das variáveis explicativas através de divisões binárias.

²⁴ Para uma formulação geral com múltiplas classes, ver Breiman et al. (1984) ou Hastie et al. (2009, cap. 9).

Ambas as medidas assumem valores máximos quando as classes estão equilibradas e valores mínimos quando o nó contém observações de uma única classe. Por exemplo, no índice de Gini, se $p_m = 0,5$, então $G(p_m) = 0,5$ (impureza máxima); já se $p_m = 0,9$, obtém-se $G(p_m) = 0,18$, refletindo maior homogeneidade do nó.

Em cada nó, o algoritmo CART seleciona a divisão que maximiza a redução total da impureza, dada por,

$$\Delta I = I(m) - \left(\frac{N_{esq}}{N_m} I(esq) + \frac{N_{dir}}{N_m} I(dir) \right). \quad (3.9)$$

De forma intuitiva, o algoritmo pode ser entendido como uma construção progressiva de um conjunto de perguntas simples do tipo “sim/não”. Em cada passo, escolhe-se a variável e o ponto de corte que melhor separam os dados em dois grupos mais homogêneos do que o conjunto original. Este procedimento é repetido recursivamente em cada subconjunto gerado, e assim sucessivamente, até que se atinja um critério de paragem. Cada percurso desde a raiz até a uma folha corresponde, assim, a uma sequência de decisões que conduz a uma previsão final.

Apesar da sua clareza conceptual e elevada interpretabilidade, as árvores de decisão apresentam uma limitação fundamental: elevada variância. Pequenas variações nos dados de treino podem conduzir a árvores substancialmente diferentes, comprometendo a estabilidade das previsões. Esta fragilidade motiva o recurso a métodos de agregação, que procuram reduzir a variabilidade do estimador sem sacrificar excessivamente a sua capacidade de discriminação.

3.3.2 Bootstrap e Bagging: motivação e formalização

A instabilidade das árvores de decisão motiva o recurso a métodos de agregação. O *bootstrap aggregating (bagging)* foi proposto como uma estratégia para reduzir a variância de modelos instáveis, mantendo o seu baixo enviesamento.

A técnica de *bootstrap* consiste em gerar múltiplas amostras com reposição a partir do conjunto original de treino. Formalmente, a partir da Equação (3.2) constroem-se B amostras *bootstrap* $\mathcal{T}^{*1}, \dots, \mathcal{T}^{*B}$, cada uma contendo n observações selecionadas aleatoriamente com

reposição²⁵. Intuitivamente, cada amostra *bootstrap* mantém o tamanho do conjunto original, mas inclui observações repetidas e deixa outras de fora. Ao ajustar uma árvore a cada amostra, obtêm-se previsões ligeiramente diferentes, e a agregação por voto tende a ser mais estável do que uma única árvore.

Para cada amostra ajusta-se um classificador $\hat{f}^{*b}(x)$. No caso da classificação, a previsão agregada é obtida por voto maioritário, correspondendo à classe k que maximiza a frequência de previsões:

$$\hat{f}_{\text{bag}}(x) = \text{mode}\{\hat{f}^{*1}(x), \dots, \hat{f}^{*B}(x)\}, \quad (3.10)$$

onde *mode* representa a moda, ou seja, a classe mais frequentemente prevista pelas B árvores.

A lógica estatística subjacente é que a agregação de múltiplos modelos aproximadamente independentes conduz a uma redução significativa da variância do estimador final.

De forma intuitiva, cada árvore construída a partir de uma amostra *bootstrap* fornece uma “opinião” sobre a classe do jogador. Algumas árvores erram, outras acertam, mas o voto conjunto tende a ser mais estável do que qualquer árvore individual. É este princípio — muitas decisões simples combinadas — que está na base do ganho de robustez introduzido pelo *bagging*.

3.3.3 Random Forest: introdução de aleatoriedade adicional

O algoritmo Random Forest estende o *bagging* introduzindo um segundo nível de aleatoriedade. Para além da amostragem *bootstrap* das observações, em cada divisão de cada árvore apenas é considerado um subconjunto aleatório de m variáveis ($m < p$), selecionado a partir do total de p preditores (tipicamente $m \approx \sqrt{p}$ para a classificação). Esta restrição força as árvores a explorarem diferentes estruturas de correlação nos dados, garantindo que as árvores individuais sejam menos correlacionadas entre si. O efeito prático é um reforço na redução da variância do modelo final, sem um aumento substancial do viés.

²⁵ Hastie et al. (2009) altera a notação de \mathcal{T} para Z para representar o conjunto de treino no contexto do *Bootstrap*. No presente trabalho opta-se por manter-se a notação já usada, por razões de consistência e clareza expositiva.

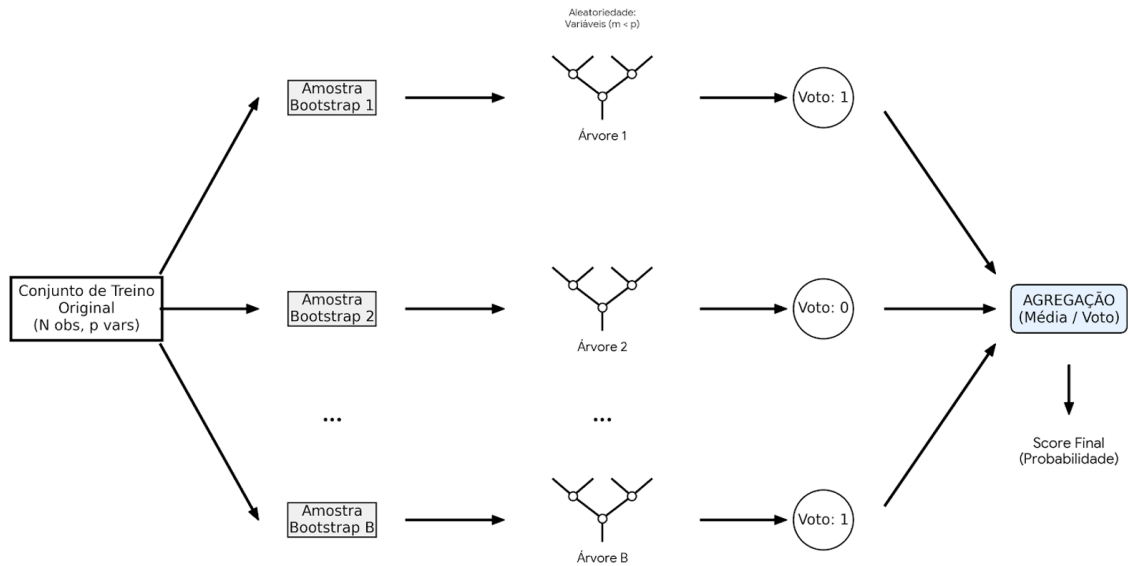


Figura 3. 4 - Esquema conceptual do Random Forest

O procedimento, ilustrado esquematicamente na Figura 3.4, pode ser descrito da seguinte forma:

- Para $b = 1, \dots, B$, gera-se uma amostra *bootstrap* do conjunto de treino como indicado anteriormente em 3.3.2;
- Constrói-se uma árvore de decisão;
- Em cada nó, selecionam-se aleatoriamente m variáveis candidatas à divisão (em vez de todas as p);
- A árvore cresce até aos critérios de paragem sem poda²⁶
- As previsões finais são agregadas por voto maioritário.

A previsão final resulta da agregação das previsões individuais. Para classificação, e visando obter um *score* de risco contínuo entre 0 e 1, a probabilidade estimada é dada pela fração de árvores que votam na classe positiva (classe rara ou minoritária).

$$\hat{p}(Y = 1|x) = \frac{1}{B} \sum_{b=1}^B \mathbb{1}(\hat{y}_b(x) = 1), \quad (3.11)$$

²⁶ Significa que a árvore cresce até aos critérios de paragem definidos (por exemplo, tamanho mínimo do nó e/ou ausência de ganho adicional). A “poda” (*pruning*) é um procedimento de pós-processamento que remove ramos/divisões pouco úteis para simplificar a árvore e reduzir sobreajuste; no Random Forest, tende a não ser necessária porque a variância é controlada pela agregação de muitas árvores.

Se muitas árvores “votarem” positivo, o *score* aproxima-se de 1; caso contrário, este aproxima-se de 0. A Figura 3.4 sintetiza este processo, evidenciando como a diversidade do modelo é induzida tanto pela variação das amostras de treino como pela seleção aleatória de variáveis.

3.3.4 Importância das variáveis, interpretação, avaliação e validação

Uma vantagem adicional do Random Forest é a possibilidade de avaliar a importância relativa das variáveis explicativas. A diminuição média da impureza quantifica o contributo de cada variável para a separação das classes ao longo de todas as árvores, ao passo que a importância por permutação avalia a degradação do desempenho do modelo quando os valores de uma variável são perturbados, mantendo as restantes constantes.

Estas medidas são particularmente relevantes em contextos regulatórios, onde a transparência e a interpretação dos resultados são essenciais para o apoio à decisão.

Para além do seu valor interpretativo, os modelos desenvolvidos permitem uma avaliação rigorosa do desempenho preditivo. Dado o forte desequilíbrio entre classes, a avaliação recorre a validação cruzada estratificada e a métricas adequadas a problemas de classes raras.

Formalização das métricas e do limiar de decisão

Seja $s_i = \hat{P}(Y = 1 | X = x_i)$ o *score* atribuído ao jogador i . Fixado um limiar $\tau \in (0,1)$, define-se a decisão binária (ou classificação) por:

$$\hat{y}_i(\tau) = \mathbb{1}(s_i \geq \tau). \quad (3.12)$$

No conjunto de teste, a comparação entre $\hat{y}_i(\tau)$ e y_i induz a matriz de confusão, com:

- $TP(\tau)$: verdadeiros positivos (positivos corretamente sinalizados);
- $FP(\tau)$: falsos positivos (negativos indevidamente sinalizados);
- $TN(\tau)$: verdadeiros negativos;
- $FN(\tau)$: falsos negativos (positivos não sinalizados).

As métricas utilizadas neste trabalho são então definidas por:

$$\text{Sensibilidade/Recall}(\tau) = \frac{TP(\tau)}{TP(\tau) + FN(\tau)}, \quad (3.13)$$

$$\text{Precisão/Precision } (\tau) = \frac{TP(\tau)}{TP(\tau) + FP(\tau)}, \quad (3.14)$$

$$\text{Especificidade } (\tau) = \frac{TN(\tau)}{TN(\tau) + FP(\tau)}, \quad (3.15)$$

$$F1(\tau) = \frac{2 \cdot \text{Precision } (\tau) \cdot \text{Recall } (\tau)}{\text{Precision } (\tau) + \text{Recall } (\tau)}. \quad (3.16)$$

A curva ROC representa, para τ variável, o compromisso entre a taxa de verdadeiros positivos, ou seja, $TPR(\tau) = \text{Recall } (\tau)$ e a taxa de falsos positivos $FPR(\tau) = 1 - \text{Especificidade } (\tau)$.

A AUC-ROC sintetiza essa capacidade discriminatória global.

Já a curva Precisão–Revocação (PR) representa a *Precision* (τ) em função de *Recall* (τ) e é especialmente informativa quando a classe positiva é rara, dado que se concentra no desempenho sobre os positivos; nesse caso, a AUC-PR fornece uma síntese mais alinhada com o objetivo de priorização.

Leitura das métricas

Em termos operacionais, cada métrica traduz uma dimensão distinta do desempenho. A sensibilidade (*recall*), também conhecida por revocação, mede a capacidade do modelo em não deixar escapar casos positivos, sendo que, quanto maior, menor o risco de falsos negativos.

A precisão (*precision*) mede a “qualidade” das sinalizações: quanto maior, maior a proporção de alertas que correspondem efetivamente a casos positivos, reduzindo o trabalho desperdiçado com falsos positivos.

Já a medida F1 resume o compromisso entre as anteriores, sendo útil quando se pretende equilibrar detecção e carga operacional.

Quanto à especificidade, esta quantifica a capacidade de não sinalizar jogadores da classe de referência, o que é particularmente importante quando a prevalência de positivos é baixa.

Por fim, as áreas sob as curvas AUC-ROC e AUC-PR avaliam a capacidade de ordenação do modelo ao longo de todos os limiares. A primeira oferece uma visão global de separação entre classes, enquanto a segunda é tipicamente mais informativa em contextos de classes

raras (ou minoritárias), por se centrar no desempenho sobre a classe positiva e na utilidade do ranking nos primeiros lugares.

Estas métricas podem ser avaliadas para diferentes limiares de decisão, explicitando o compromisso operacional entre maximização da detecção e contenção do volume de alertas.

3.4 Modelação

Com base no enquadramento metodológico e nos fundamentos estatísticos apresentados nos pontos anteriores, procedeu-se à implementação do modelo preditivo adotado, onde foram tomadas algumas opções ao nível da modelação.

O objetivo central consistiu na construção de um classificador supervisionado capaz de distinguir, ao nível do jogador, perfis comportamentais compatíveis com o risco de branqueamento de capitais e financiamento do terrorismo, a partir de variáveis agregadas que sintetizam a sua atividade transacional ao longo do período de observação disponível.

A unidade de análise adotada corresponde ao jogador, sendo o problema formulado como uma tarefa de classificação supervisionada binária, em que a variável resposta assume o valor 1 para os jogadores pertencentes ao conjunto dos “casos positivos” e o valor 0 para os restantes jogadores da “amostra de referência”. Para além da classificação binária, o modelo fornece ainda uma probabilidade estimada de pertença à classe positiva, interpretável como um *score* de risco, permitindo ordenar os jogadores segundo o grau de risco estimado.

A técnica de modelação utilizada foi o Random Forest, conforme justificado no ponto 3.2, atendendo à sua adequação a dados tabulares com variáveis heterogéneas, à sua capacidade de capturar relações não lineares e interações complexas, e à sua robustez em contextos de forte desequilíbrio entre classes. Adicionalmente, o Random Forest permite a obtenção de medidas internas de relevância das variáveis, aspeto particularmente relevante num enquadramento regulatório.

O conjunto de dados foi dividido em dois subconjuntos mutuamente exclusivos, treino e teste, através de uma partição estratificada, assegurando a preservação da proporção entre classes. Durante a fase de treino, recorreu-se a validação cruzada estratificada, com o objetivo de obter estimativas mais estáveis do desempenho do modelo e de reduzir a dependência de uma única partição treino–teste.

O desequilíbrio acentuado entre a classe positiva e a classe negativa foi tratado através da seleção de métricas de avaliação adequadas e da utilização de ponderação diferencial das classes durante o treino do modelo. Técnicas de reamostragem não foram privilegiadas, devido ao risco de introdução de enviesamentos e de identificação de padrões espúrios.

A escolha do limiar de decisão é tratada neste estudo como uma decisão analítica e operacional, separada do processo de treino do modelo, sendo posteriormente informada pela análise empírica dos resultados e pelo contexto regulatório subjacente.

3.5 Análise de resultados

3.5.1 Desempenho global do modelo

O desempenho do modelo foi avaliado ao nível do jogador, após agregação das transações em variáveis comportamentais (cf. exemplo ilustrativo em 3.2.1), o que permite representar cada jogador por um perfil agregado e comparar a classe positiva com a classe de referência de forma consistente. O conjunto de dados apresenta um forte desequilíbrio entre classes, com 15 074 jogadores na classe de referência e apenas 100 jogadores na classe positiva, o que justifica a utilização de métricas adequadas à deteção de eventos raros.

O conjunto de dados foi inicialmente dividido de forma estratificada em subconjuntos de treino e teste, preservando a proporção entre casos positivos e jogadores da amostra de referência. Em particular, foram reservados 80% dos jogadores para treino e 20% para teste, mantendo-se o conjunto de teste independente para avaliação externa do modelo. A validação cruzada estratificada a 5 folds foi posteriormente aplicada apenas ao conjunto de treino, com o objetivo de selecionar os hiperparâmetros do Random Forest.

Durante a fase de treino foi realizada validação cruzada estratificada (*5 folds*) para seleção dos hiperparâmetros do Random Forest. A melhor combinação observada correspondeu a $mtry = 6$ e $min_node_size = 1$, apresentando uma AUC-PR média de 0,770 no conjunto de treino, indicando uma boa capacidade de priorização dos casos positivos. O modelo final foi estimado com 500 árvores, sendo estes parâmetros mantidos na avaliação em teste.

No conjunto de teste, o modelo apresentou uma AUC-ROC de 0,902 e uma AUC-PR de 0,552, evidenciando capacidade discriminatória relevante num contexto de desequilíbrio de

classes, em que a distinção entre variabilidade legítima e comportamentos potencialmente ilícitos é particularmente exigente.

Considerando um limiar de decisão de 0,20, e de forma a avaliar a robustez dos resultados, o procedimento de treino e teste foi repetido cinco vezes com diferentes partições estratificadas dos dados. Os resultados mostram uma sensibilidade (*recall*) entre 0,654 e 0,774, com valor médio de 0,702, indicando que, em média, o modelo recupera cerca de 70% dos casos positivos no conjunto de teste. A precisão média foi de 0,553 e a medida F1 de 0,618, refletindo um compromisso equilibrado entre capacidade de deteção e controlo do número de falsos positivos.

Tabela 3. 7 - Estabilidade das métricas no conjunto de teste.

Estabilidade das métricas no conjunto de teste				
Cinco repetições com diferentes partições estratificadas (limiar = 0.20)				
Estatística	Sensibilidade (Recall)	Precisão	F1	Especificidade
Mínimo	0.654	0.500	0.567	0.995
Média	0.702	0.553	0.618	0.996
Máximo	0.774	0.595	0.658	0.997

A especificidade manteve-se elevada em todas as repetições, com valor médio de 0,996, confirmando que a grande maioria dos jogadores da classe de referência não é indevidamente sinalizada.

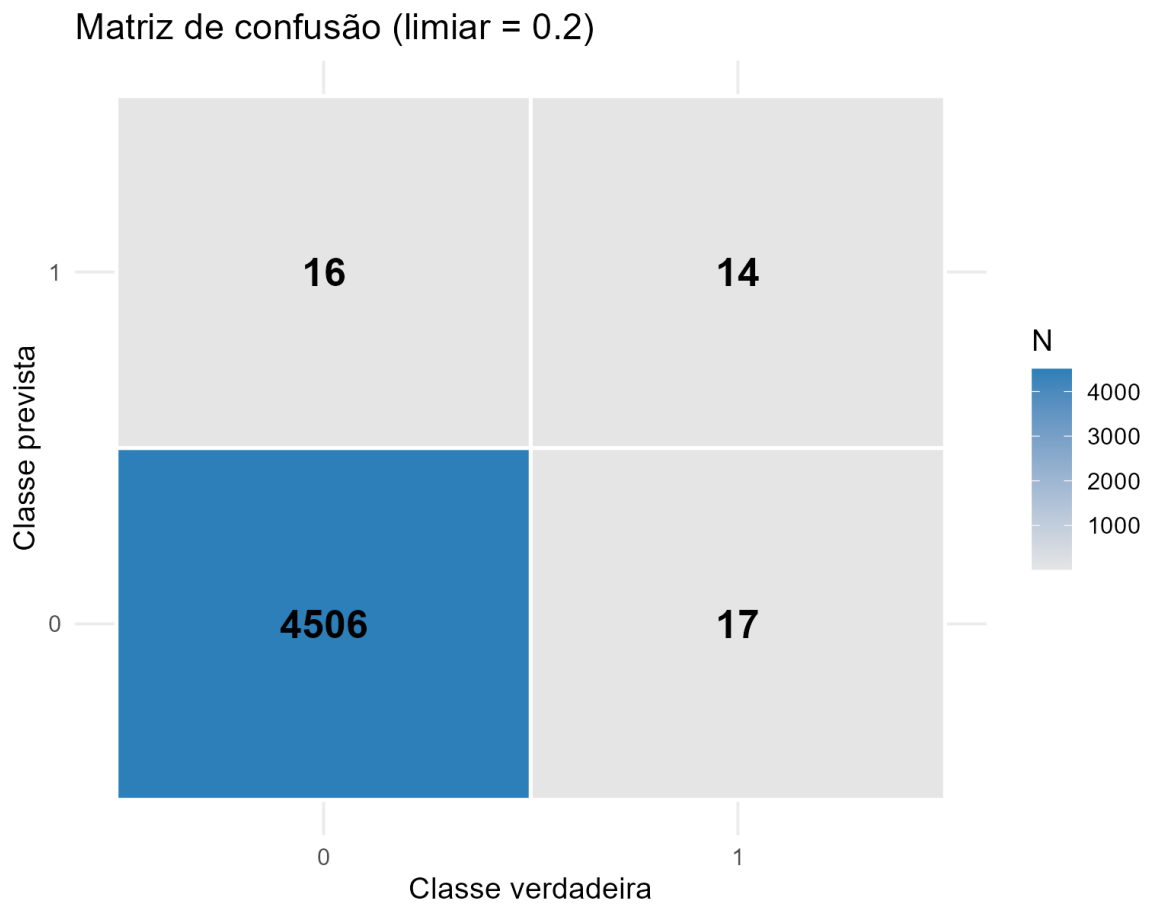


Figura 3. 5 - Matriz de confusão (heatmap), para o limiar adotado.

Em termos de matriz de confusão, os resultados reforçam a adequação do modelo como instrumento de triagem e priorização de casos, permitindo concentrar recursos investigativos num subconjunto reduzido de jogadores com maior probabilidade estimada de risco.

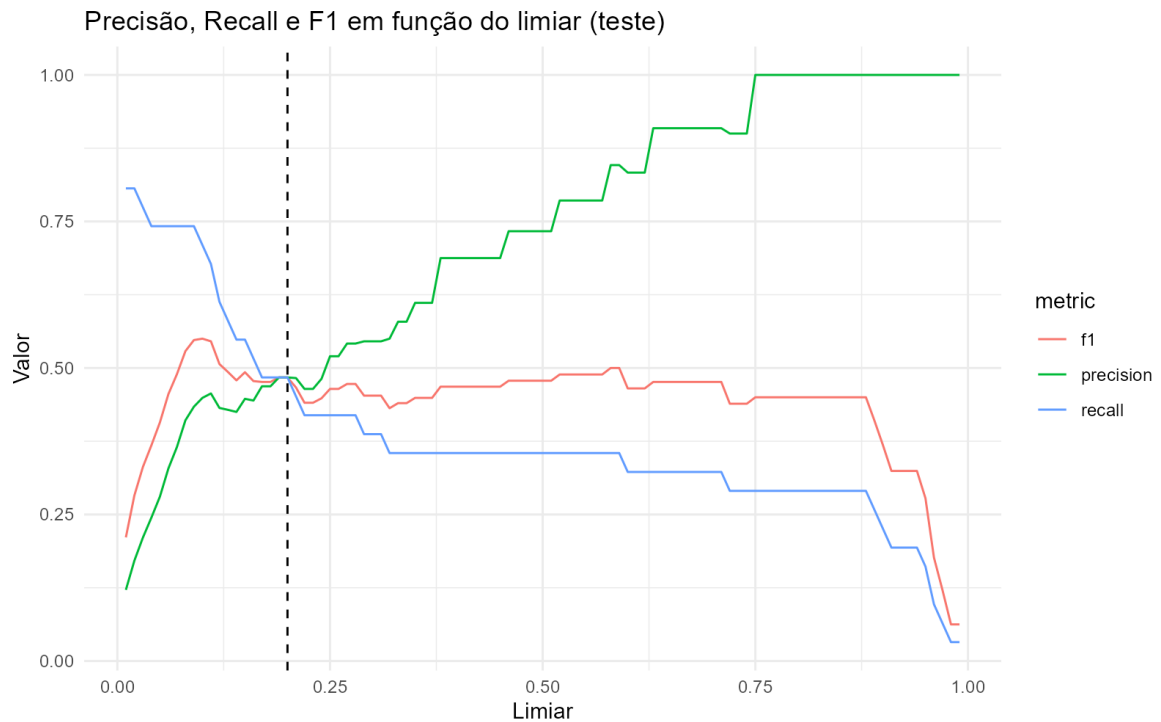


Figura 3. 6 - Evolução das métricas em função do limiar de decisão.

Já a Figura 3.6 ilustra a evolução das métricas de precisão, sensibilidade e F1 em função do limiar de decisão, evidenciando o compromisso esperado entre maximização da detecção de casos positivos e contenção do número de alertas. O limiar de 0,20 foi adotado por privilegiar a minimização de falsos negativos, mantendo simultaneamente um volume de sinalizações compatível com um contexto operacional realista.

3.5.2 Avaliação do poder discriminatório e ordenação por risco

Neste ponto avalia-se a capacidade do modelo para ordenar os jogadores por risco, independentemente do limiar de decisão adotado. Para tal, recorrem-se às curvas ROC e Precisão–Revocação e à análise da distribuição dos scores por classe, que permitem avaliar a capacidade discriminatória e a ordenação por risco ao longo de diferentes limiares.

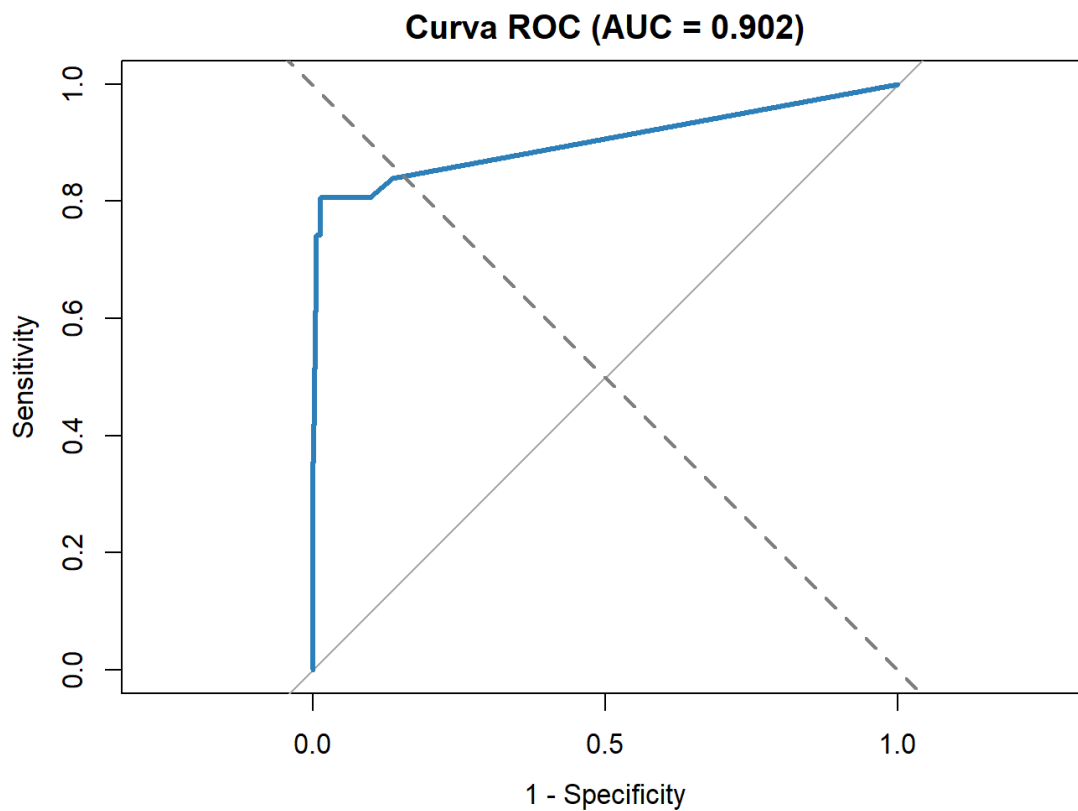


Figura 3. 7 - Curva ROC.

A Figura 3.7 apresenta a curva ROC, cuja área sob a curva (AUC-ROC) foi de 0,902. Em termos simples, isto significa que o modelo consegue, na maioria das situações, atribuir um score de risco mais elevado a jogadores da classe positiva do que a jogadores da classe de referência, indicando boa capacidade de separação global.

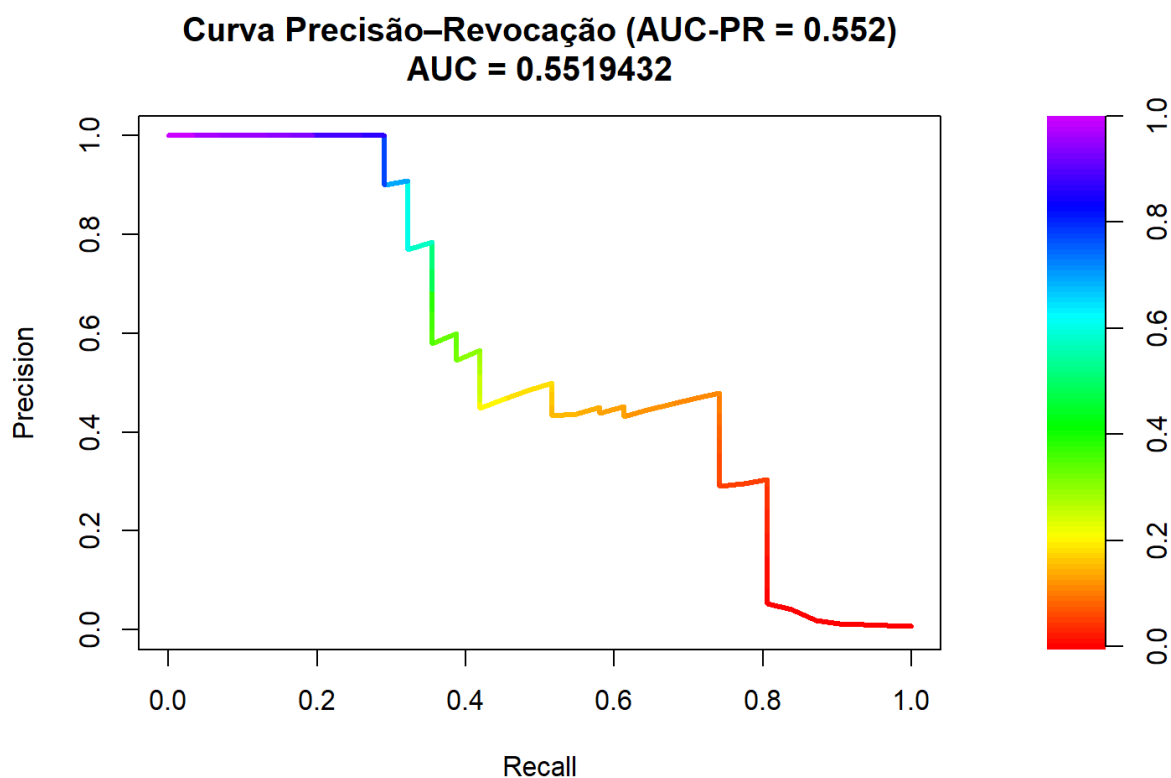


Figura 3. 8 - Curva Precisão–Revocação.

Contudo, em problemas com óbvios desequilíbrios de classes, como o presente, a curva Precisão–Revocação é normalmente mais informativa, por se focar diretamente no desempenho sobre a classe positiva. A Figura 3.8 mostra a curva Precisão–Revocação, com $AUC-PR = 0,552$, valor substancialmente superior ao nível de prevalência esperado da classe positiva no conjunto de dados. Este resultado indica que, quando se observam os jogadores com scores mais elevados, existe uma concentração significativa de casos positivos, reforçando a utilidade do modelo como instrumento de triagem e priorização.

Em conjunto, as duas curvas confirmam que o modelo é capaz de classificar e, sobretudo, priorizar jogadores com maior probabilidade estimada de pertencer à classe positiva, permitindo ajustar posteriormente o limiar de decisão em função das necessidades operacionais (volume de alertas aceitável versus maximização da deteção).

Essa concentração da classe positiva em valores mais elevados, ainda que com sobreposição parcial, pode também ser evidenciada através representações mais “clássicas”.

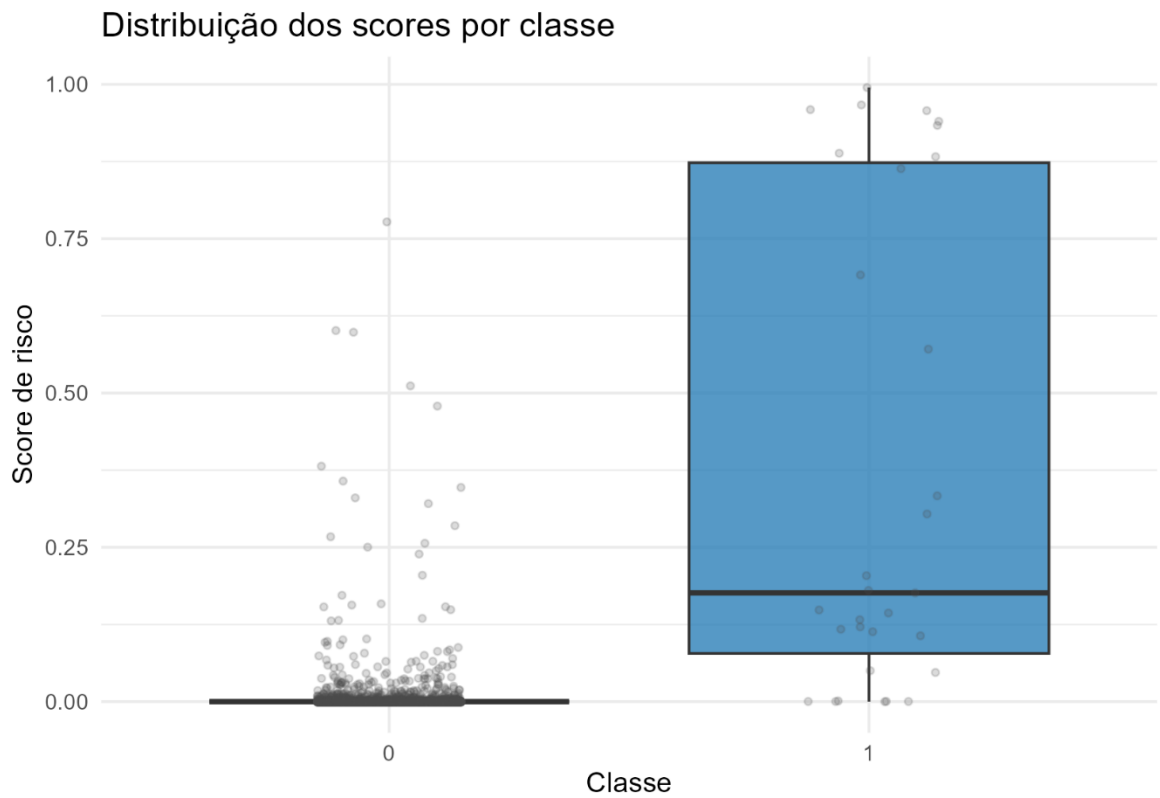


Figura 3. 9 - Distribuição dos scores de risco por classe.

A Figura 3.9 apresenta a distribuição dos scores de risco atribuídos pelo modelo a jogadores da classe positiva e negativa. Confirma-se, em média, uma tendência para *scores* mais elevados da classe positiva, ainda que com sobreposição entre distribuições, característica expectável em problemas de deteção de ilícitos.

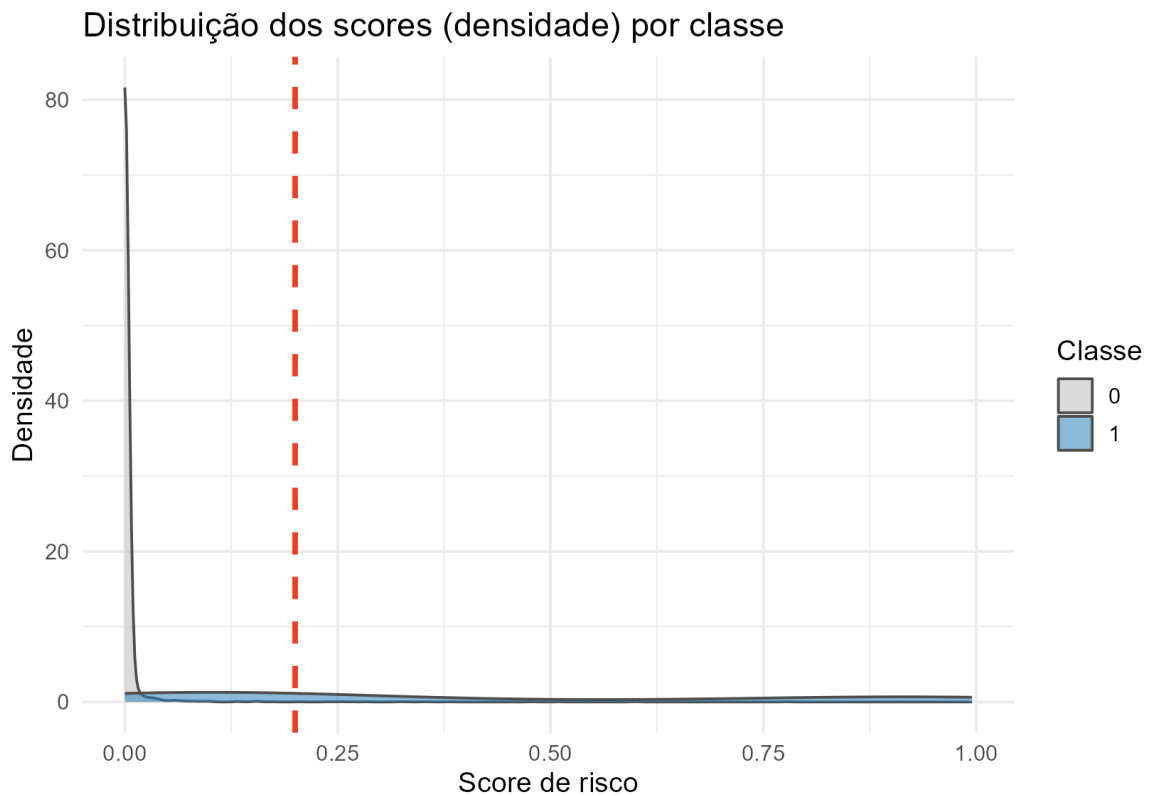


Figura 3. 10 - Distribuição contínua dos scores (densidade) por classe.

A representação da densidade complementa o *boxplot*, evidenciando a concentração relativa dos scores ao longo do intervalo $[0,1]$ em cada classe, e permitindo ao mesmo tempo visualizar a sua relação com o limiar de decisão definido.

3.5.3 Interpretação do modelo e priorização de casos

Importância das variáveis

Para compreender o que está a “puxar” o *score* de risco, analisou-se a importância das variáveis do Random Forest através de importância por permutação. Em termos simples, esta medida testa o seguinte: *Baralhar (permutar) uma variável, piora o modelo?* Se piorar muito, é porque a variável era relevante.

Tabela 3. 8 - Variáveis mais relevante.

Variáveis mais relevantes no modelo Obtida por Permutação (Random Forest)	
Variável	Importância
vol_tot	0.00875
active_days	0.00838
mov_p99	0.00670
vol_dep	0.00663
vol_wdr	0.00654
mov_p90	0.00648
n_dep	0.00600
mov_median	0.00575
n_ops	0.00554
mov_mean	0.00552

A Tabela 3.8 apresenta as variáveis mais relevantes. Observa-se que o modelo atribui maior peso sobretudo a três dimensões do comportamento do jogador. Em primeiro lugar ao volume financeiro total movimentado (*vol_tot*, *vol_dep*, *vol_wdr*), em segundo à duração/continuidade da atividade (*active_days*), e em terceiro à presença de montantes elevados (estatísticas de cauda e de posição, como *mov_p99*, *mov_p90*, *mov_median*, *mov_mean*, *mov_max*). Em linguagem simples: o modelo tende a sinalizar como mais arriscados os perfis com muito dinheiro a entrar/sair, atividade prolongada e transações com valores elevados, em vez de se basear apenas num único *outlier* pontual.

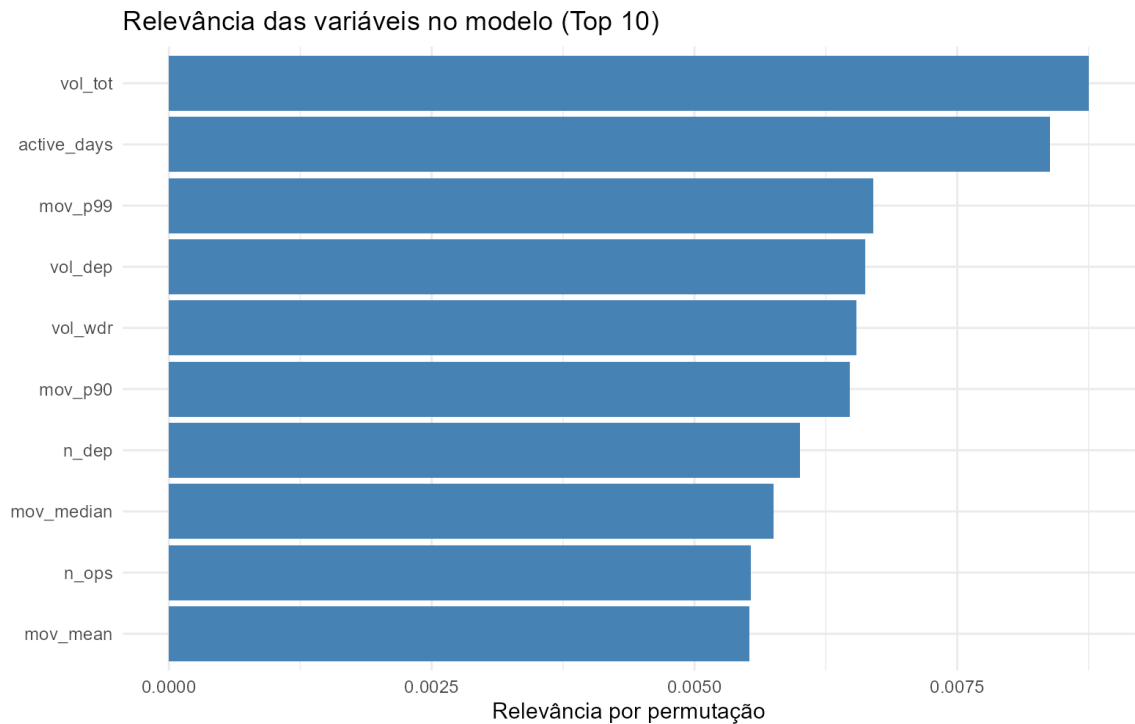


Figura 3. 11 - Relevância das variáveis (Top 10).

Por fim, surgem também variáveis ligadas à intensidade transacional (n_dep , n_ops) e à relação entre entradas e saídas ($ratio_wdr_dep$). Isto é coerente com a lógica de detecção por perfis agregados: o risco emerge do conjunto do comportamento, e não de uma única operação isolada.

Priorização de casos: utilidade prática do score

Para avaliar a utilidade operacional do modelo, ordenaram-se os jogadores do conjunto de teste por *score* de risco e analisou-se a concentração de casos positivos nos primeiros lugares do *ranking*. A lógica é simples: se o modelo for útil, então os “casos positivos” devem aparecer mais frequentemente no topo da lista.

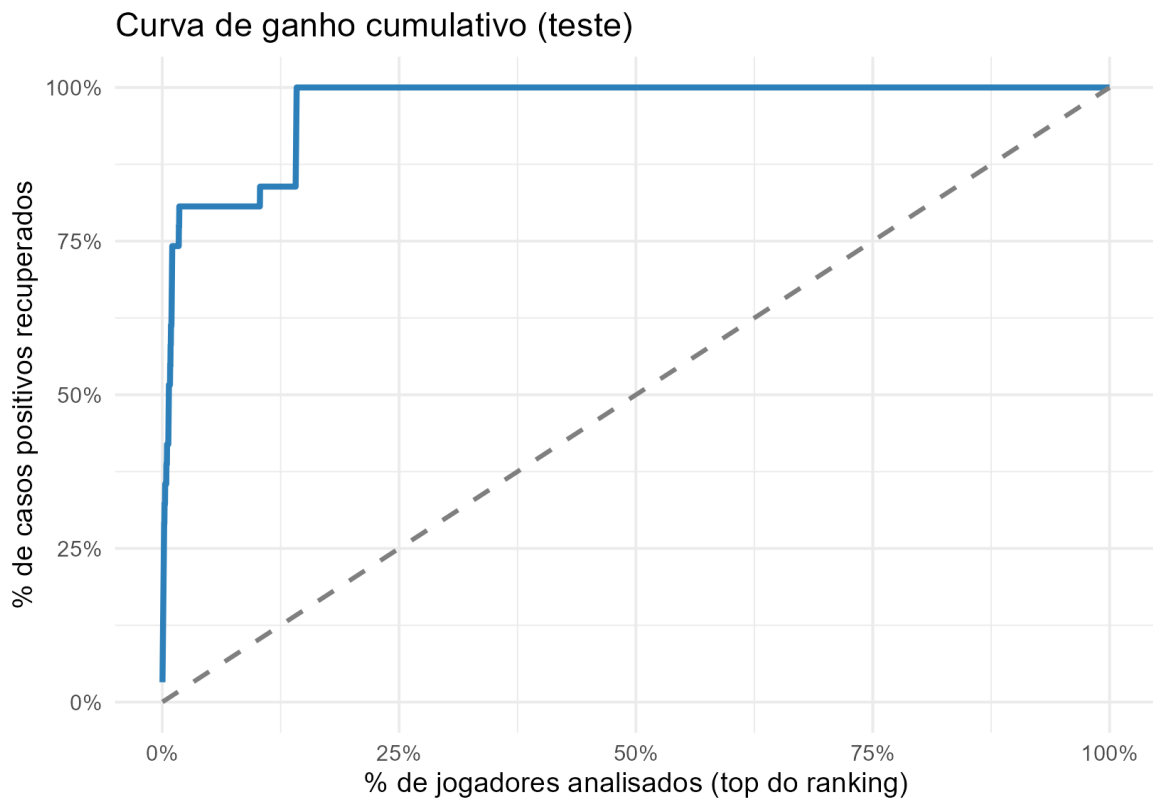


Figura 3. 12 - Curva de ganho cumulativo.

Tabela 3. 9 - Concentração de casos positivos.

Concentração de casos positivos no topo do ranking		
Proporção de positivos nos jogadores com maior score (conjunto de teste)		
Top-N	Casos positivos	Taxa de positivos
50	23	46%
100	25	25%

Os resultados confirmam essa concentração. Ao analisar apenas os 50 jogadores com *score* mais elevado, 23 pertencem à chamada “classe positiva”, correspondendo a uma taxa de acerto de 46%. Ao alargar para os 100 primeiros, surgem 25 casos positivos, correspondendo a 25%. Estes valores são muito superiores ao que seria expectável por seleção aleatória, demonstrando que o modelo permite reduzir significativamente o universo de análise e

concentrar o esforço investigativo num subconjunto pequeno de jogadores com maior probabilidade estimada de risco.

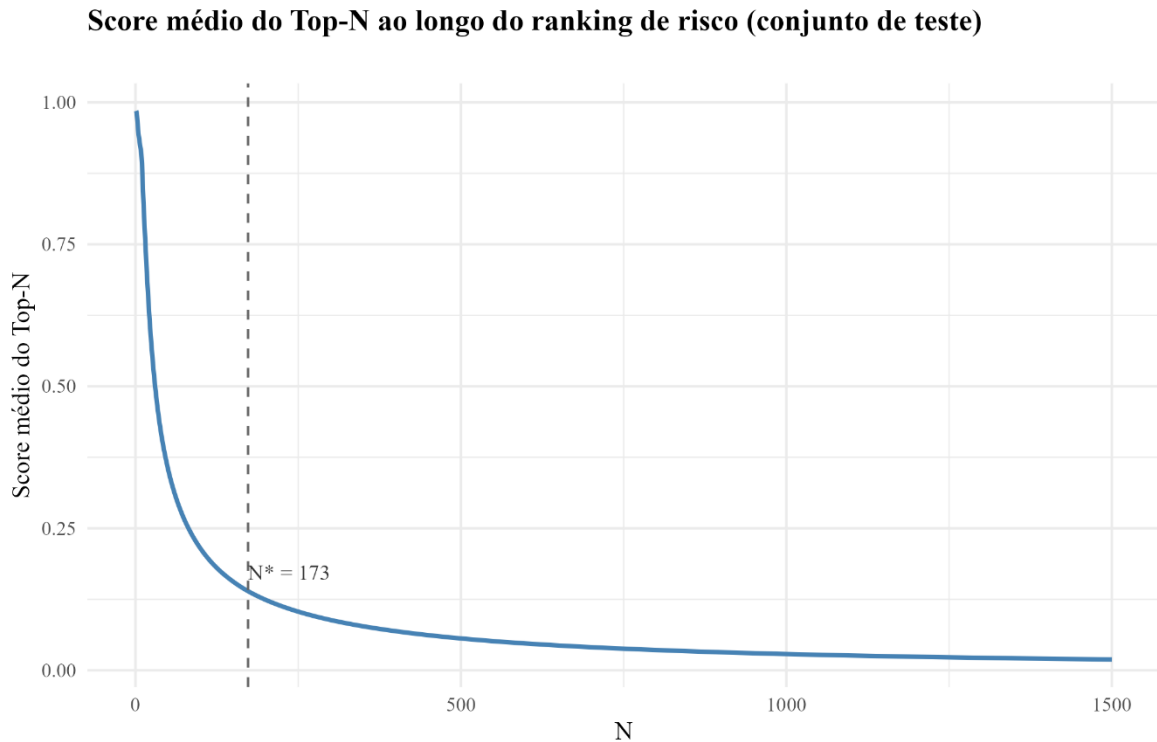


Figura 3. 13 - Score médio do Top-N ao longo do ranking de risco.

Esta leitura pode ser visualizada pela evolução do *score* médio quando se considera o Top- N de jogadores do *ranking* (Figura 3.13). À medida que N aumenta, o *score* médio decresce de forma acentuada nos primeiros lugares e, posteriormente, estabiliza, evidenciando retornos marginais decrescentes na expansão do universo de análise. A figura assinala ainda um ponto de inflexão N^* estimado por uma heurística geométrica²⁷, que pode servir como referência inicial para a definição de um verdadeiro N operacional.

Em termos práticos, tal significa que o modelo pode mesmo ser utilizado como ferramenta de triagem muito prática e funcional: em vez de analisar milhares de jogadores, quem tem

²⁷ O ponto N^* é obtido por uma heurística geométrica do tipo *knee detection*: identifica-se o valor de N que maximiza a distância perpendicular entre a curva empírica do *score* médio do Top- N e a reta que liga os seus extremos (entre $N = 1$ e $N = N_{\max}$). Este critério fornece uma referência automática e reproduzível para localizar a transição entre a zona de queda rápida e a zona de estabilização. Não constitui um ótimo estatístico universal, devendo ser interpretado como um apoio à decisão e articulado com restrições operacionais (capacidade operacional de análise, custo de falsos positivos e tolerância ao risco).

de decidir, pode começar por definir um “Top- N ” e, consoante a capacidade operacional disponível, escolher um N compatível com o volume de alertas que consegue gerir.

3.5.4 Definição do limiar de decisão e implicações operacionais

A escolha do limiar de decisão traduz-se num compromisso operacional entre maximizar a deteção de casos positivos e conter o número de alertas a analisar. Em termos simples, um limiar mais baixo sinaliza mais jogadores (aumentando a sensibilidade), mas também aumenta a probabilidade de falsos positivos; inversamente, um limiar mais elevado reduz o volume de alertas, mas tende a deixar escapar mais casos positivos.

Se a Figura 3.6. ilustrou anteriormente a variação de precisão, sensibilidade e F1 em função do limiar, a Tabela 3.10 complementa esta leitura com exemplos concretos, evidenciando como pequenas alterações no limiar afetam simultaneamente o número de alertas gerados e a proporção de casos positivos recuperados.

Tabela 3. 10 - Impacto do limiar no volume de alertas e desempenho.

Impacto do limiar no volume de alertas e desempenho					
Exemplos de trade-off operacional (conjunto de teste)					
Limiar	Alertas	Positivos_detetados	Recall	Precisao	
0.1	50	23	0.742	0.460	
0.2	30	14	0.452	0.467	
0.3	23	13	0.419	0.565	

Neste estudo adotou-se o limiar 0,20 como uma opção conservadora, por favorecer a minimização de falsos negativos, mantendo ainda assim um volume de sinalizações compatível com um cenário realista de análise humana. Importa sublinhar que este limiar não constitui uma escolha universal, devendo ser ajustado em função da capacidade operacional e do apetite ao risco da entidade responsável pela monitorização.

Importa por fim sublinhar que os resultados apresentados ao longo deste capítulo não esgotam as possibilidades de análise dos dados e do modelo desenvolvido. A mesma informação pode ser explorada através de múltiplas representações gráficas e análises complementares, quer ao nível do desempenho do modelo, quer ao nível da interpretação das variáveis e dos perfis comportamentais identificados. Para manter o foco analítico do capítulo e assegurar a legibilidade da exposição, algumas dessas análises adicionais são apresentadas em anexo, a título ilustrativo.

CONCLUSÃO

O jogo online apresenta características operacionais que, embora reduzam alguns riscos clássicos, como o uso de numerário, não eliminam vulnerabilidades relevantes em matéria de branqueamento de capitais e financiamento do terrorismo. A elevada frequência transacional, a rapidez na movimentação de fundos e a possibilidade de estruturar padrões aparentemente legítimos, tornam a detecção de risco um desafio complexo, que raramente se resolve de forma direta, exigindo metodologias capazes de identificar combinações subtis de comportamentos ao longo do tempo.

Neste enquadramento, a presente dissertação formulou o problema como uma tarefa de classificação supervisionada ao nível do jogador, agregando transações individuais em variáveis comportamentais que capturam volumes, rácios, intensidade, dispersão e medidas de cauda. A opção pelo modelo Random Forest revelou-se adequada ao contexto, não só pela sua capacidade de modelar relações não lineares e interações complexas sem necessidade de especificação funcional prévia, mas também pela robustez demonstrada face ao forte desequilíbrio entre classes e pela disponibilização de mecanismos de interpretação, nomeadamente através da análise da importância das variáveis por permutação.

Os resultados obtidos evidenciam a utilidade prática do modelo sobretudo enquanto instrumento de triagem e priorização. Ao atribuir um score de risco e ordenar os jogadores, o algoritmo consegue concentrar uma proporção significativa de casos positivos no topo do ranking, reduzindo o universo de análise para um subconjunto compatível com a capacidade dos processos de revisão humana. A análise de sensibilidade confirmou o compromisso esperado entre a detecção de casos relevantes e a contenção de falsos positivos, tendo-se adotado o limiar de decisão de 0,20 como uma escolha conservadora. Esta opção é coerente com o enquadramento regulatório vigente, no qual o custo de não sinalizar um caso potencialmente ilícito tende a ser substancialmente superior ao custo operacional de analisar um alerta adicional.

A análise das variáveis mais influentes sugere que o risco, tal como capturado pelo modelo, emerge essencialmente da conjugação de três dimensões do comportamento do jogador: os volumes financeiros movimentados, a continuidade da atividade ao longo do tempo e a presença de valores elevados nas caudas da distribuição. Esta leitura é consistente com a

intuição regulatória, indicando que padrões persistentes, envolvendo montantes relevantes e alguma simetria de fluxos, justificam um escrutínio mais aprofundado do que operações pontuais isoladas.

Não obstante os resultados alcançados, o estudo apresenta limitações que devem ser devidamente enquadradas. Destaca-se, desde logo, o potencial ruído na rotulagem da classe negativa, uma vez que a “amostra de referência” pode conter casos não detetados, bem como a assimetria temporal entre os históricos longos dos “casos positivos” e a janela de observação mais curta da população de referência. A limitação mais relevante decorre, contudo, dos estritos requisitos de confidencialidade e de minimização do risco de “reidentificação” da origem dos dados, que condicionaram opções metodológicas estruturais. Em particular, não foi possível maximizar a extensão temporal da amostra de referência nem segmentar explicitamente a análise por tipologia de jogo oferecida, uma vez que tal permitiria inferências indiretas sobre características operacionais específicas da entidade exploradora. Acresce que, tratando-se de casos reais previamente sinalizados, a divulgação excessivamente detalhada de padrões transacionais poderia expor assinaturas operacionais idiossincráticas, justificando a opção por um nível elevado de agregação dos dados.

Importa sublinhar que estas restrições se circunscrevem ao contexto académico e de divulgação pública do presente trabalho. Em ambientes controlados, como os dos operadores ou da entidade reguladora, onde as limitações de anonimização da fonte não se aplicam, a metodologia proposta pode ser facilmente expandida para incorporar históricos mais extensos e variáveis de contexto específicas, potenciando ainda mais a sua capacidade de deteção.

Como linhas de desenvolvimento futuro, destaca-se a possibilidade de expandir o conjunto de variáveis utilizadas, analisar a estabilidade temporal do *score* de risco e proceder a uma calibração mais fina das probabilidades estimadas, incorporando formalmente uma perspetiva de risco associado à própria definição do limiar de decisão. Seria igualmente interessante a exploração sistemática de modelos alternativos, como métodos de *gradient boosting* ou arquiteturas sequenciais, bem como a integração de informação e de contexto

operacional, nomeadamente a atividade de jogo associada, sempre que compatível com os requisitos de privacidade e confidencialidade.

Em síntese, o principal contributo desta dissertação reside na demonstração, com dados reais e num enquadramento regulatório concreto, de que uma abordagem supervisionada baseada em perfis comportamentais agregados ao nível do jogador pode apoiar de forma objetiva a priorização do risco de BC/FT no jogo online regulado, reforçando a capacidade de monitorização, sem substituir a indispensável validação humana e investigativa, mas antes complementando-a.

BIBLIOGRAFIA

- AMLYZE. (2025). *goAML: A critical tool in global AML compliance*.
<https://amlyze.com/goaml/>
- Assembleia da República. (2017, 18 de agosto). Lei n.º 83/2017 (Estabelece medidas de combate ao branqueamento de capitais e ao financiamento do terrorismo). *Diário da República*, 1.ª série(159), 4576-4634.
- Australian Transaction Reports and Analysis Centre. (2022a, 1 de março). *AUSTRAC commences civil penalty proceedings against Crown Melbourne and Crown Perth*.
<https://www.austrac.gov.au/business/media-release/austrac-commences-civil-penalty-proceedings-against-crown-melbourne-and-crown-perth>
- Australian Transaction Reports and Analysis Centre. (2022b, 30 de novembro). *AUSTRAC commences civil penalty proceedings against The Star Pty Limited and The Star Entertainment QLD Limited*.
<https://www.austrac.gov.au/business/media-release/austrac-commences-civil-penalty-proceedings-against-star-pty-limited-and-star-entertainment-qld-limited>
- Banco de Portugal. (s.d.). *Grupo de Ação Financeira – GAFI*. <https://www.bportugal.pt/page/grupo-de-accao-financeira-gafi>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
<https://doi.org/10.1023/A:1010933404324>
- Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984). *Classification and regression trees*. Wadsworth.

- Cont, R. (2001). Empirical properties of asset returns: Stylized facts and statistical issues. *Quantitative Finance*, 1(2), 223–236. <https://doi.org/10.1080/713665670>
- Doddamani, S. S., Girish, K. K., & Bhowmik, B. (2024). Money laundering detection in imbalanced e-wallet transactions with threshold optimization. In *2024 IEEE 9th International Conference for Convergence in Technology (I2CT)* (pp. 1–6). IEEE. <https://doi.org/10.1109/I2CT61223.2024.10544197>
- Elkan, C. (2001). The foundations of cost-sensitive learning. *Proceedings of the 17th International Joint Conference on Artificial Intelligence*, 973–978. <http://ijcai.org/Proceedings/01/Papers/162.pdf>
- European Committee for Standardization. (2024). *Online gambling: Markers of harm in support of identification and prevention of risky and problem gambling behaviour* (prEN 18144). CEN.
- Fan, J., Shar, L. K., Zhang, R., Liu, Z., Yang, W., Niyato, D., Mao, B., & Lam, K.-Y. (2025). *Deep learning approaches for anti-money laundering on mobile transactions: Review, framework, and directions*. arXiv. <https://doi.org/10.48550/arXiv.2503.10058>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Financial Action Task Force. (2009). *Vulnerabilities of casinos and gaming sector*. <https://www.fatf-gafi.org/content/dam/fatf-gafi/reports/Vulnerabilities%20of%20Casinos%20and%20Gaming%20Sector.pdf>

- Financial Transactions and Reports Analysis Centre of Canada. (2024). *Special bulletin on laundering the proceeds of crime through online gambling sites* (No. FINTRAC-2024-SB001). <https://fintrac-canafe.gc.ca>
- Frick, H., Chow, F., Kuhn, M., Mahoney, M., Silge, J., & Wickham, H. (2026). *rsample: General resampling infrastructure*. R package. <https://rsample.tidymodels.org>
- Gambling Commission. (2022, 17 de agosto). *Entain to pay £17 million for social responsibility and anti-money laundering failures*. <https://www.gamblingcommission.gov.uk/news/article/entain-to-pay-gbp17-million-for-social-responsibility-and-anti-money>
- Gambling Commission. (2025). *Emerging money-laundering and terrorist-financing risks*. <https://www.gamblingcommission.gov.uk/licensees-and-businesses/guide/emerging-money-laundering-and-terrorist-financing-risks>
- Ghaharian, K., Abarbanel, B., Kraus, S. W., Singh, A., & Bernhard, B. (2023). Players gonna pay: Characterizing gamblers and gambling-related harm with payments transaction data. *Computers in Human Behavior*, *143*, 107717. <https://doi.org/10.1016/j.chb.2023.107717>
- Grau, J., Grosse, I., & Keilwagen, J. (2015). PRROC: Computing and visualizing precision-recall and receiver operating characteristic curves in R. *Bioinformatics*, *31*(15), 2595–2597. <https://doi.org/10.1093/bioinformatics/btv153>
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer. <https://doi.org/10.1007/978-0-387-84858-7>

- Hopfgartner, N., Auer, M., Helic, D., & Griffiths, M. D. (2024). Using artificial intelligence algorithms to predict self-reported problem gambling among online casino gamblers from different countries using account-based player data. *International Journal of Mental Health and Addiction*. Publicação online antecipada. <https://doi.org/10.1007/s11469-024-01312-1>
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An introduction to statistical learning: with applications in R* (2nd ed.). Springer. <https://doi.org/10.1007/978-1-0716-1418-1>
- Jančíková, E., & Veselovská, S. (2018). The new technologies and the fight against money laundering and the terrorism financing. In *Second International Scientific Conference on Economics and Management - EMAN 2018* (pp. 334–341). <https://doi.org/10.31410/EMAN.2018.334>
- Jullum, M., Løland, A., Huseby, R. B., Ånonsen, G., & Lorentzen, J. (2020). Detecting money laundering transactions with machine learning. *Journal of Money Laundering Control*, 23(1), 173–186. <https://doi.org/10.1108/JMLC-07-2019-0055>
- Kuhn, M., Vaughan, D., & Hvitfeldt, E. (2026). *yardstick: Tidy characterizations of model performance*. R package. <https://yardstick.tidymodels.org>
- Levi, M. (2009). E-gaming and money laundering risks: A European overview. *ERA Forum*, 10, 533–546. <https://doi.org/10.1007/s12027-009-0143-2>
- Min, M., & Lee, D. A. (2024). Illegal online gambling site detection using multiple resource-oriented machine learning. *Journal of Gambling Studies*, 40, 2237–2255. <https://doi.org/10.1007/s10899-024-10337-z>

Ministério da Justiça. (1995, 15 de março). Decreto-Lei n.º 48/95 (Revê o Código Penal aprovado pelo Decreto-Lei n.º 400/82, de 23 de setembro, e procede à sua republicação). *Diário da República*, 1.ª série-A(63), 1350-1416.

Ministério do Interior. (1927, 3 de dezembro). Decreto n.º 14643 (Promulga a nova lei do jogo). *Diário do Governo*, 1.ª série(268), 2453-2458.

Nguyen, H. H. X., Dang, T. K., & Tran-Truong, P. T. (2024). Money laundering detection using a transaction-based graph learning approach. In *2024 18th International Conference on Ubiquitous Information Management and Communication (IMCOM)* (pp. 1–8). IEEE. <https://doi.org/10.1109/IMCOM60618.2024.10418307>

Peres, F., Fallacara, E., Manzoni, L., Castelli, M., Popovič, A., Rodrigues, M., & Estevens, P. (2021). Time series clustering of online gambling activities for addicted users' detection. *Applied Sciences*, *11*(5), 2397. <https://doi.org/10.3390/app11052397>

Presidência do Conselho de Ministros. (2012, 22 de junho). Decreto-Lei n.º 129/2012 (Aprova a orgânica do Turismo de Portugal, I. P.). *Diário da República*, 1.ª série(120), 3126-3135.

Presidência do Conselho de Ministros. (2015, 29 de abril). Decreto-Lei n.º 66/2015 (Aprova o Regime Jurídico dos Jogos e Apostas Online). *Diário da República*, 1.ª série(83), 2248-2282.

R Core Team. (2025). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing. <https://www.R-project.org>

- Robin, X., Turck, N., Hainard, A., Tiberti, N., Lisacek, F., Sanchez, J.-C., & Müller, M. (2011). pROC: An open-source package for R and S+ to analyze and compare ROC curves. *BMC Bioinformatics*, *12*, 77. <https://doi.org/10.1186/1471-2105-12-77>
- Savage, D., Wang, Q., Chou, P., Zhang, X., & Yu, X. (2016). *Detection of money laundering groups using supervised learning in networks*. arXiv. <https://arxiv.org/abs/1608.00708>
- Serviço de Regulação e Inspeção de Jogos. (2025). *Relatório de atividade do jogo online em Portugal: 3.º trimestre de 2025*. Turismo de Portugal.
- Turismo de Portugal. (2015). *Regulamento n.º 903-B/2015 de 23 de dezembro. Aprova o Regulamento dos Requisitos do Sistema Técnico do Jogo Online*. Diário da República, 2.ª série, (250), 38024-(12)–38024-(29).
- United Nations Office on Drugs and Crime. (2011). *Estimating illicit financial flows resulting from drug trafficking and other transnational organized crimes*. https://www.unodc.org/documents/data-and-analysis/Studies/Illicit_financial_flows_2011_web.pdf
- U.S. Department of the Treasury. (2022, fevereiro). *National money laundering risk assessment*. <https://home.treasury.gov/system/files/136/2022-National-Money-Laudering-Risk-Assessment.pdf>
- Wan, F., & Li, P. (2024). A novel money laundering prediction model based on a dynamic graph convolutional neural network and long short-term memory. *Symmetry*, *16*(3), Artigo 378. <https://doi.org/10.3390/sym16030378>

Wickham, H., Averick, M., Bryan, J., Chang, W., McGowan, L. D., François, R., Grolemund, G., Hayes, A., Henry, L., Hester, J., Kuhn, M., Pedersen, T. L., Miller, E., Bache, S. M., Müller, K., Ooms, J., Robinson, D., Seidel, D. P., Spinu, V., Takahashi, K., Vaughan, D., Wilke, C., Woo, K., & Yutani, H. (2019). Welcome to the tidyverse. *Journal of Open Source Software*, 4(43), 1686. <https://doi.org/10.21105/joss.01686>

Wright, M. N., & Ziegler, A. (2017). ranger: A fast implementation of random forests for high dimensional data in C++ and R. *Journal of Statistical Software*, 77(1), 1–17. <https://doi.org/10.18637/jss.v077.i01>

ANEXOS

Anexo A — Análises complementares e representações gráficas adicionais

O presente anexo reúne um conjunto de análises complementares e representações gráficas adicionais, desenvolvidas a partir dos mesmos dados e do modelo apresentados no corpo principal do trabalho. Estas figuras ilustram outras perspectivas possíveis de leitura do desempenho do modelo, da distribuição dos *scores* de risco e da estrutura das variáveis agregadas. A sua inclusão em anexo visa enriquecer a interpretação dos resultados, sem desvirtuar o foco central do estudo nem tornar excessivamente extensa a exposição no corpo principal do texto.

A.1 Avaliação gráfica complementar do desempenho do modelo

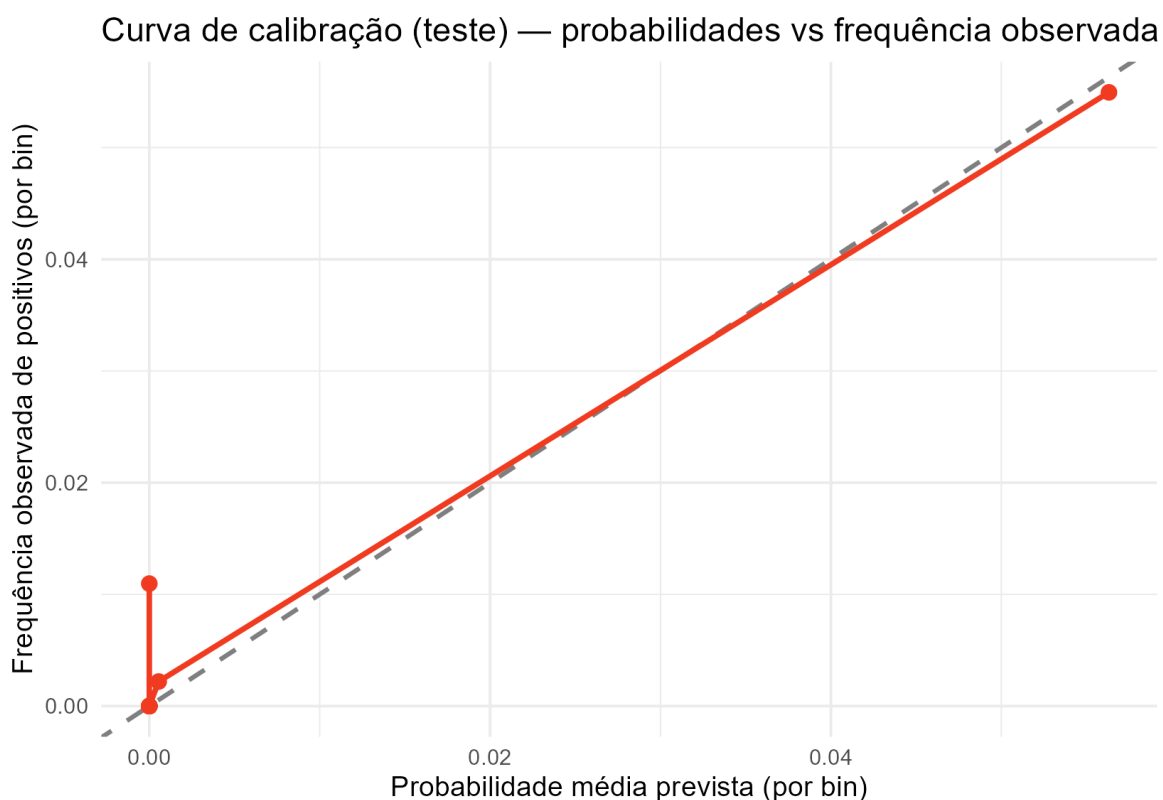


Figura A. 1 - Curva de calibração.

A curva de calibração compara as probabilidades previstas pelo modelo com as frequências observadas de casos positivos. Esta representação permite avaliar em que medida o score de

risco pode ser interpretado como probabilidade, ou se deve ser utilizado sobretudo como instrumento de ordenação relativa.

A.2 Distribuição dos scores de risco e utilidade operacional do ranking

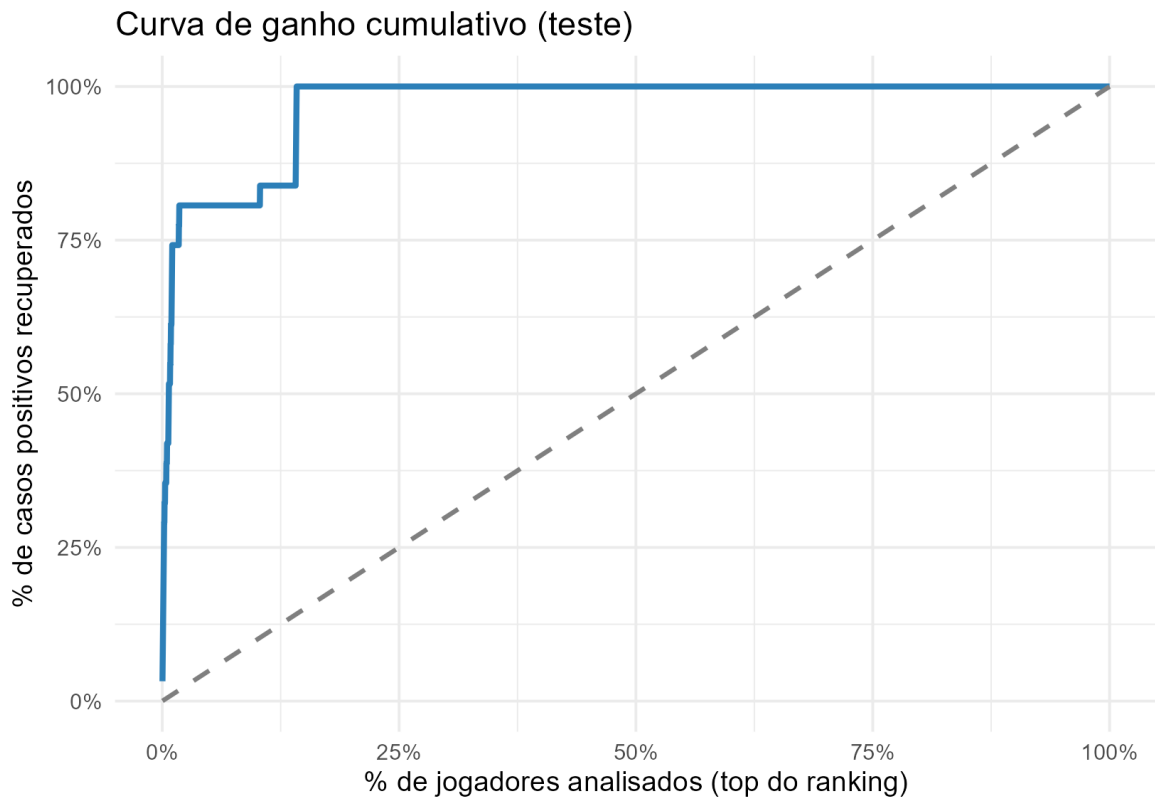


Figura A. 2 - Curva de ganho cumulativo.

A curva de ganho cumulativo ilustra a proporção de casos positivos recuperados à medida que se analisa uma fração crescente do topo do ranking de scores. A comparação com a linha de referência aleatória evidencia o ganho obtido com a utilização do modelo para priorização de casos.

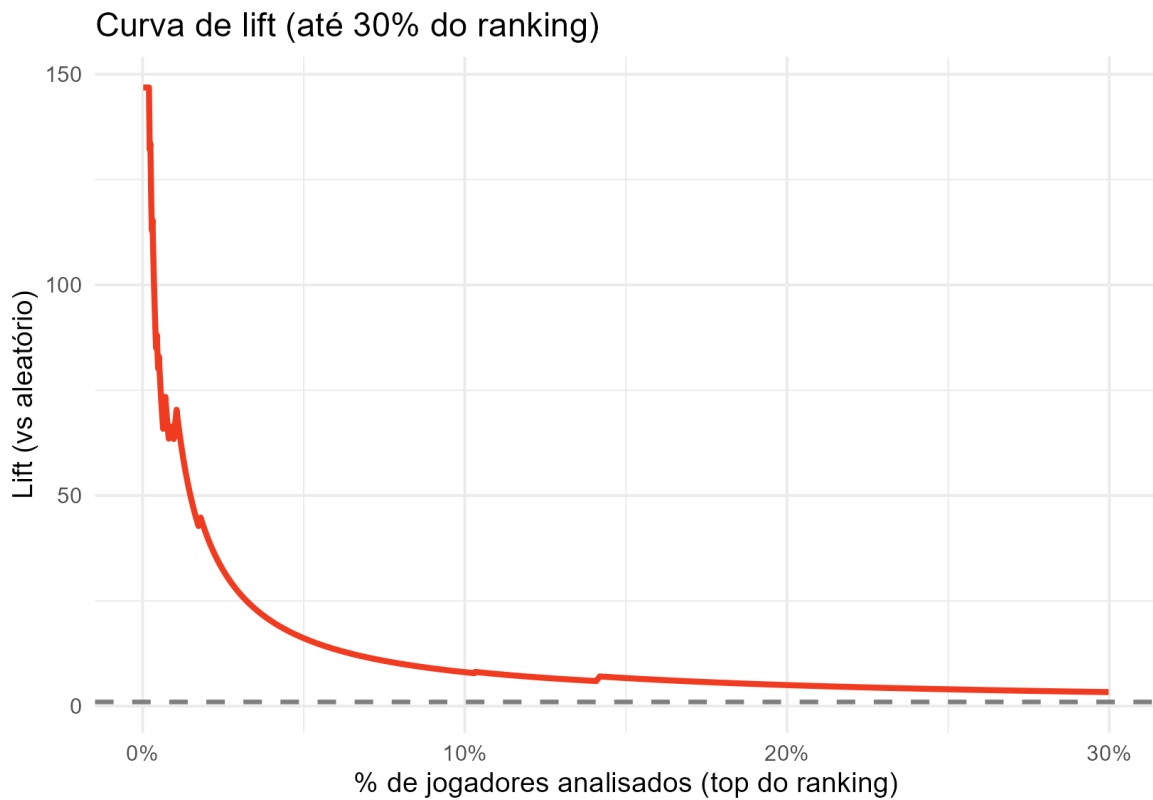


Figura A. 3 - Curva de lift.

A curva de *lift* quantifica o ganho relativo do modelo face a uma seleção aleatória, especialmente relevante nos primeiros percentis do ranking. Valores de *lift* superiores a 1 indicam um desempenho superior ao acaso, reforçando a utilidade operacional do modelo.

A.3 Interpretação das variáveis agregadas e estrutura dos dados

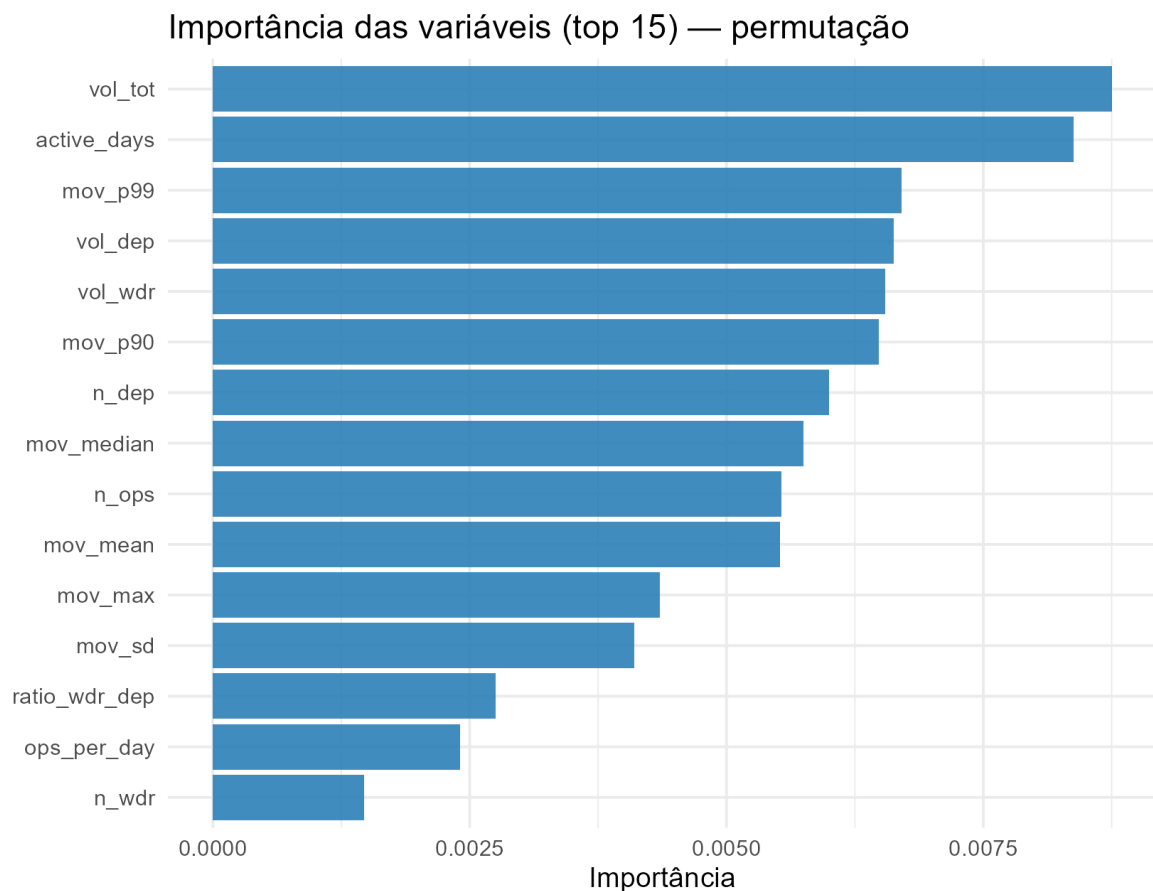


Figura A. 4 - Importância das variáveis (top 15).

A Figura A.4 apresenta as variáveis com maior contributo para o desempenho do modelo, de acordo com a medida de importância por permutação. Expandindo o já apresentado relativo à relevância das variáveis, continuando, obviamente, a observar-se uma maior importância das variáveis associadas ao volume financeiro, à intensidade transaccional e à presença de valores extremos.

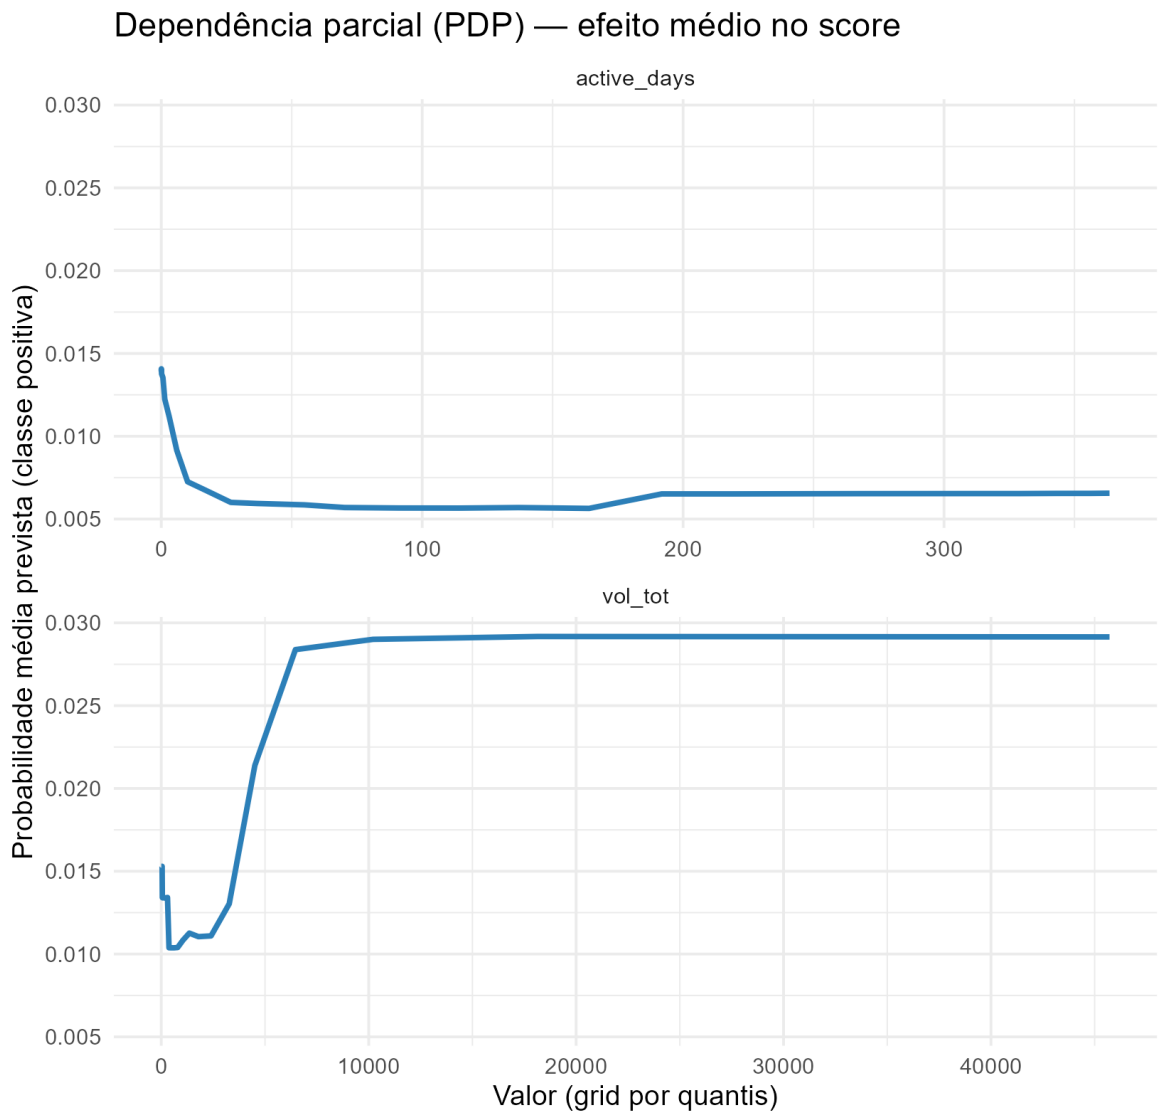


Figura A. 5 - Curvas de dependência parcial (PDP).

As curvas de dependência parcial ilustram o efeito médio de variáveis selecionadas na probabilidade prevista de pertença à classe positiva, mantendo constantes as restantes características. Estas representações são uma forma de interpretação global do modelo.

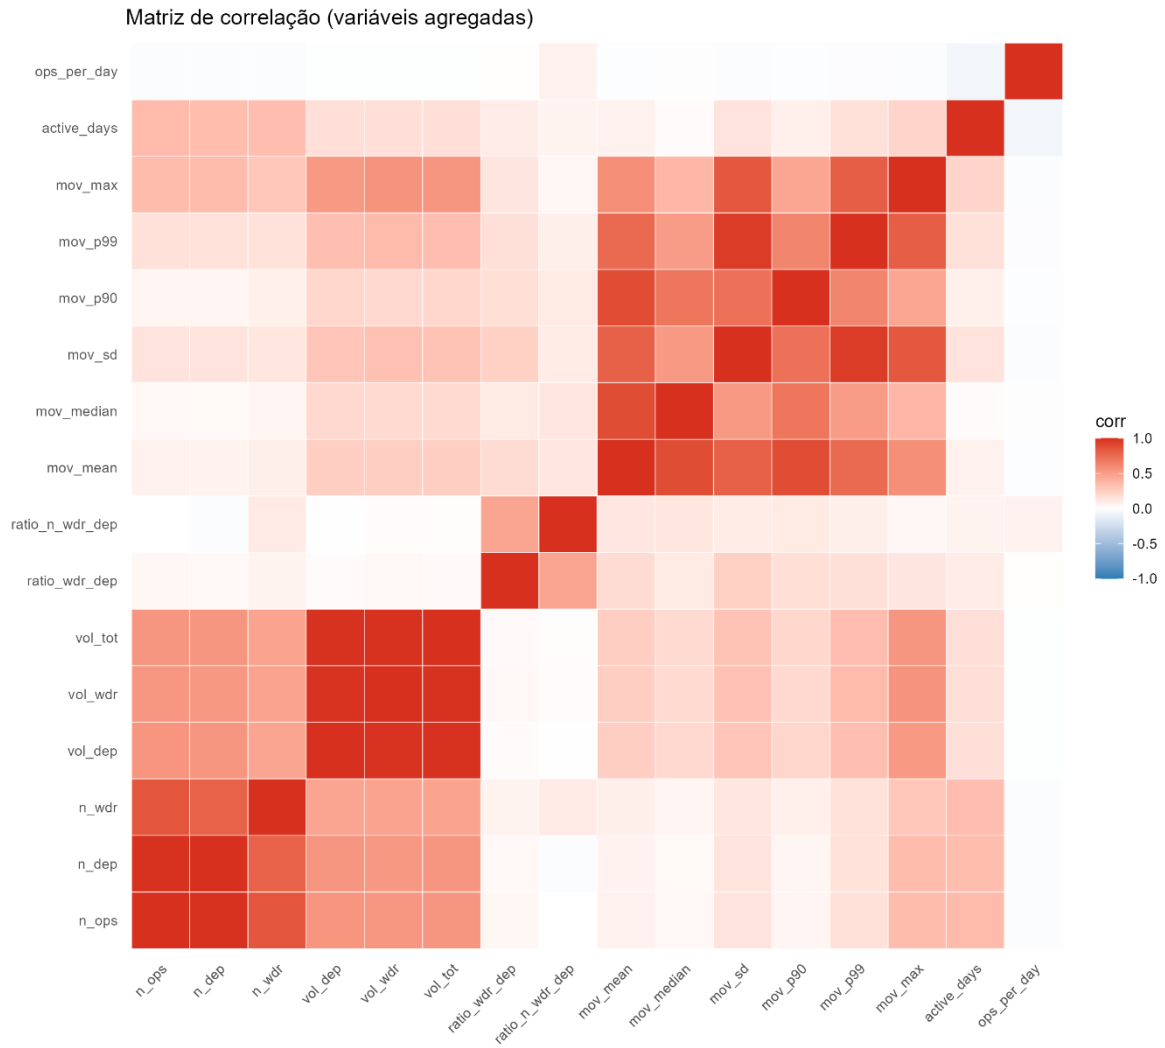


Figura A. 6 - Matriz de correlação das variáveis agregadas.

A matriz de correlação evidencia a estrutura de dependência entre as variáveis utilizadas na modelação, permitindo identificar grupos de variáveis relacionadas, sem indícios de colinearidade perfeita entre os principais atributos.

A.4 Variáveis comportamentais ao longo do ranking de risco

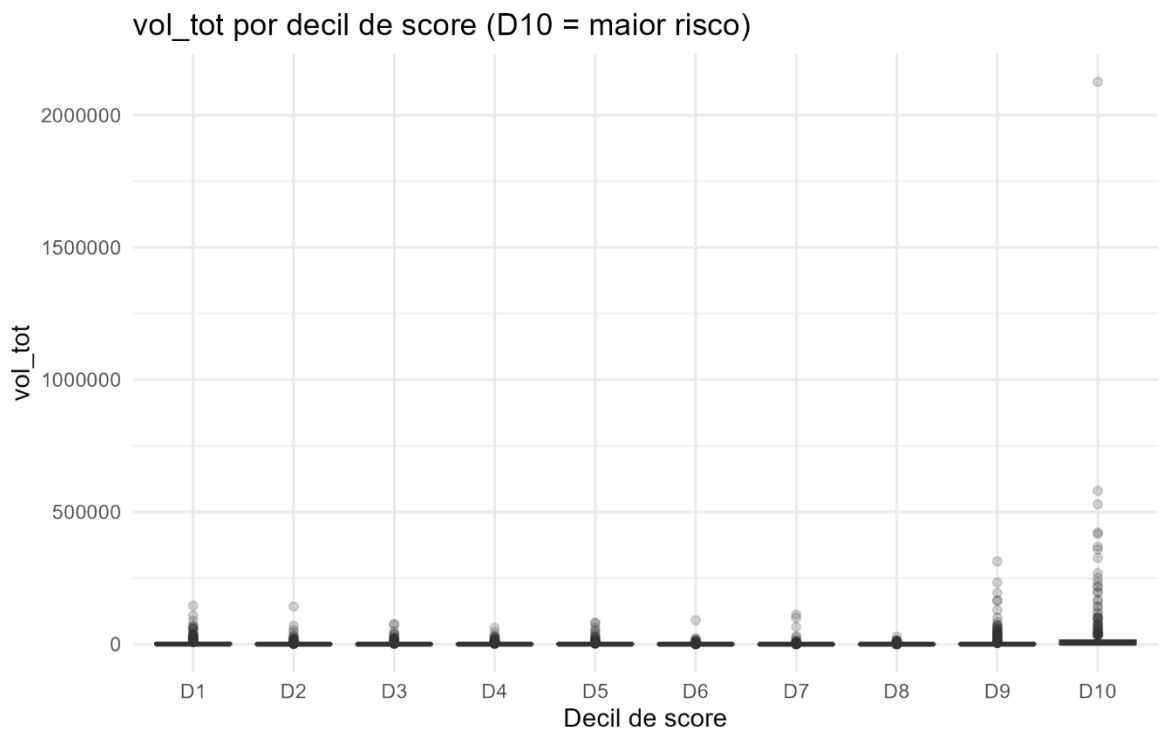


Figura A. 7 - Volume total movimentado por decis de score.

A Figura A.7 apresenta a distribuição do volume total movimentado por decis de score, observando-se uma tendência crescente ao longo do ranking, coerente com a lógica de priorização induzida pelo modelo.

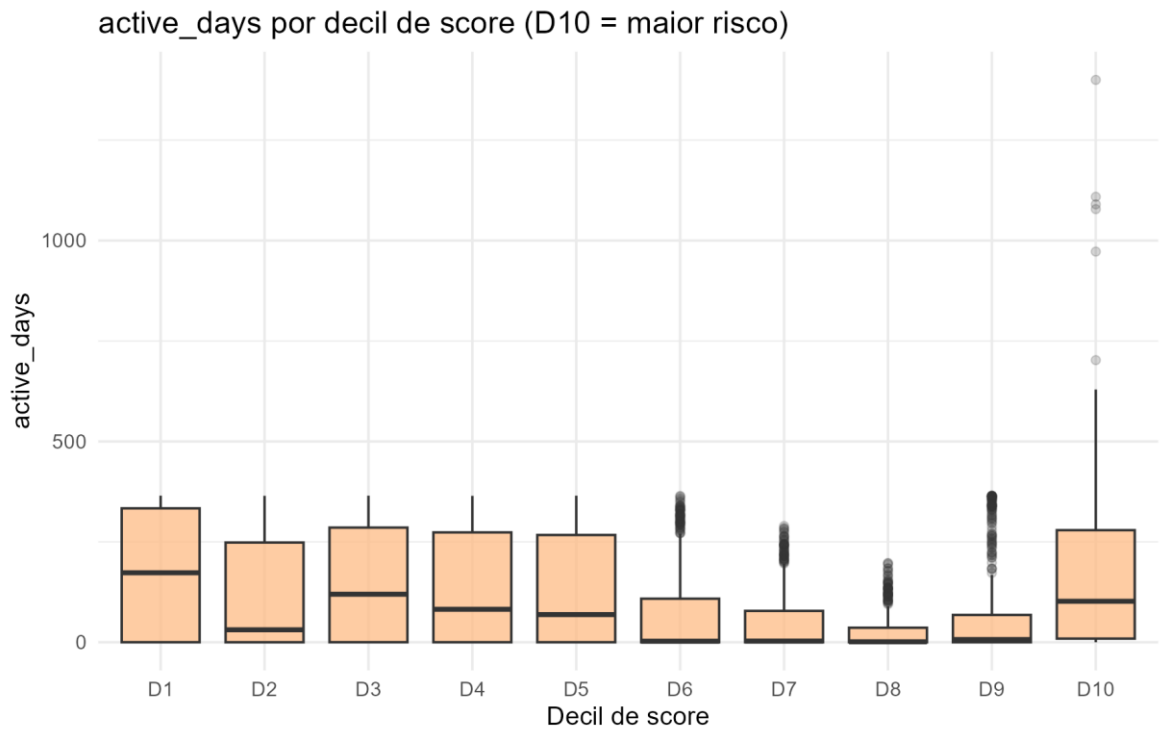


Figura A. 8 - Duração da atividade por decis de score.

Esta figura ilustra a relação entre a duração da atividade transacional e os decis de score, permitindo analisar se jogadores com scores mais elevados apresentam históricos temporais mais extensos.

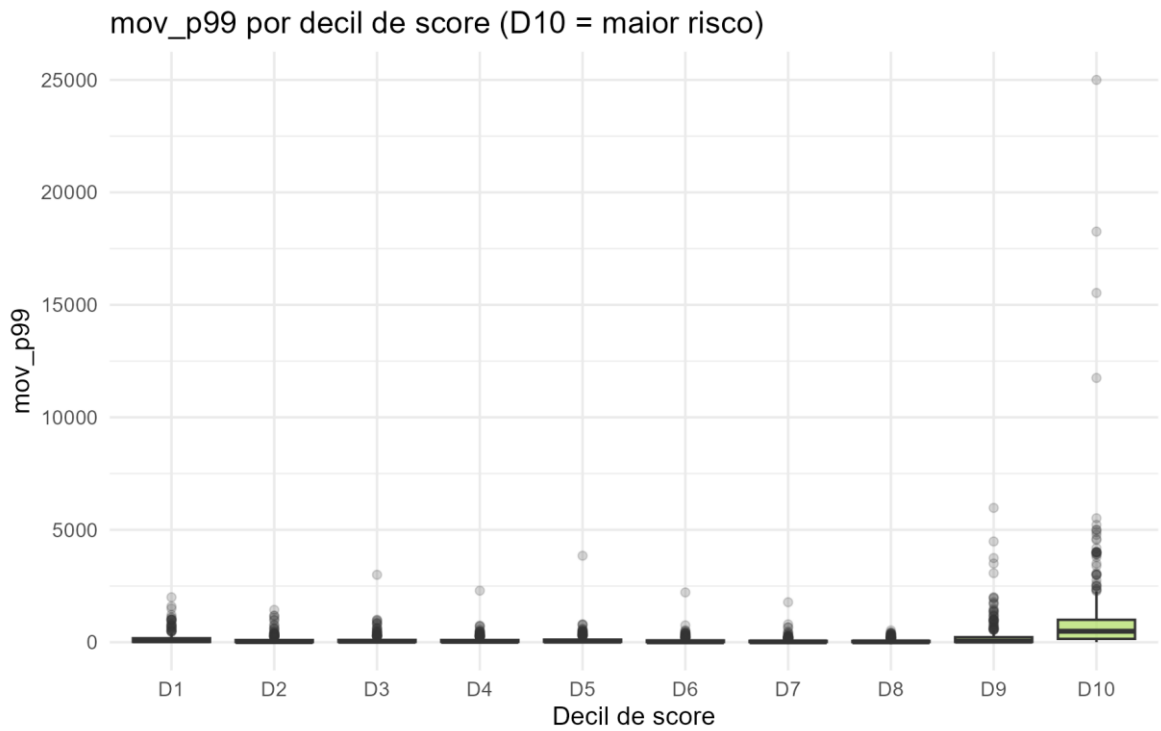


Figura A. 9 - Percentil 99 dos montantes movimentados por decis de score.

A Figura A.9 evidencia a evolução de uma medida de cauda ao longo do ranking de risco, sugerindo que valores extremos desempenham um papel relevante na diferenciação dos perfis de risco.