

Lições de Implementação de um Projeto de Ciência de Dados para Investigação Financeira: Diretrizes, Evidências e Resultados Preliminares

Dimas Cassimiro do Nascimento Filho¹, Luis Filipe Alves Pereira¹,
Igor Medeiros Vanderlei¹, Diego Marconi Pinheiro², Eraylson Galdino³,
Gustavo Callou⁴, Rodrigo Gayger Amaro⁴, Edvaldo dos Santos Veiga⁵

¹ Universidade Federal do Agreste de Pernambuco¹ (UFAPE)

Universidade Católica de Pernambuco² (UNICAP)

Universidade de Pernambuco³ (UPE)

Universidade Federal Rural de Pernambuco⁴ (UFRPE)

Polícia Civil de Pernambuco⁵ (PCPE)

{dimas.cassimiro, luis-filipe.pereira, igor.vanderlei}@ufape.edu.br
diego.silva@unicap.br, eraylson.galdino@upe.br
{rodrigo.amaro, gustavo.callou}@ufrpe.br
edvaldosantos.veiga@policiacivil.pe.gov.br

Abstract. *This paper presents guidelines, lessons learned, and preliminary evidence from a real-world data science project aimed at supporting financial investigations conducted by the Civil Police of Pernambuco. The study discusses data-centric curation, bias mitigation, flexible analytical workflows, human-centered AI, incorporation of domain knowledge, scalable processing, and continuous improvement through human feedback. Initial results from implemented modules indicate practical potential to organize evidence, prioritize alerts, and support investigative decision-making while preserving human oversight.*

Resumo. *Este artigo apresenta diretrizes, lições aprendidas e evidências preliminares de um projeto real de ciência de dados voltado ao apoio à investigação financeira pela Polícia Civil de Pernambuco. O estudo discute curadoria data-centric, mitigação de vieses, fluxos analíticos flexíveis, IA centrada no humano, incorporação de conhecimento especializado, processamento escalável e melhoria contínua por meio de feedback humano. Os resultados iniciais indicam potencial prático para organizar evidências, priorizar alertas e apoiar a tomada de decisão investigativa, preservando a supervisão humana.*

1. Introdução

A digitalização das atividades econômicas e financeiras ampliou o volume, a variedade e a complexidade dos dados utilizados em investigações, incluindo transações bancárias, vínculos societários, registros cadastrais e fontes abertas. Em muitos casos, a análise exclusivamente manual torna-se inviável, o que motiva o uso de métodos estatísticos para detecção de fraude [Bolton and Hand 2002], técnicas de análise de grafos para identificação de padrões relacionais suspeitos [Akoglu et al. 2015] e abordagens de aprendizado profundo para detecção de anomalias [Pang et al. 2021].

Apesar do avanço metodológico, a aplicação dessas técnicas em domínios sensíveis enfrenta desafios relevantes. Bases investigativas reais frequentemente contêm duplicidades, inconsistências temporais, valores ausentes e múltiplos formatos, o que pode comprometer a confiabilidade das análises e dos modelos. Nesse cenário, abordagens *data-centric* enfatizam que ganhos substanciais podem surgir da melhoria sistemática da qualidade, consistência, representatividade e governança dos dados [Jakubik et al. 2024]. Além disso, modelos treinados sobre dados históricos podem reproduzir desigualdades e impactos discriminatórios [Barocas and Selbst 2016], exigindo avaliação e mitigação cuidadosas de vieses [Mehrabi et al. 2021].

Outro requisito central é preservar a colaboração entre humanos e algoritmos. Sistemas inteligentes aplicados a contextos críticos devem apoiar, e não substituir, especialistas, seguindo princípios de IA centrada no humano [Shneiderman 2020], diretrizes de interação humano-IA [Amershi et al. 2019] e ciclos de aprendizado com *feedback* humano [Holzinger 2016]. Motivado por essas lacunas, este trabalho sistematiza diretrizes e resultados preliminares de um projeto real de Ciência de Dados para investigação financeira desenvolvido em Parceria com a Polícia Civil de Pernambuco. As contribuições são: (i) consolidar diretrizes de implantação prática; (ii) relatar evidências iniciais de uso em ambiente operacional; e (iii) discutir lições aprendidas sobre dados, modelos, infraestrutura e interação humano-IA.

2. Trabalhos Relacionados

A literatura sobre detecção de fraude e anomalias combina métodos estatísticos, aprendizado de máquina e análise relacional. Revisões recentes discutem o uso de aprendizado de máquina para detecção de fraude financeira [Hernandez Aros et al. 2024], enquanto revisões de anomalias baseadas em aprendizado profundo destacam avanços em auto-encoders, redes neurais e modelos de representação [Pang et al. 2021]. Em paralelo, métodos baseados em grafos são especialmente relevantes em investigação financeira, pois indivíduos, contas, empresas e transações formam redes complexas nas quais padrões suspeitos podem emergir de estruturas relacionais [Akoglu et al. 2015].

Em domínios críticos, a efetividade desses modelos depende não apenas do algoritmo, mas também da qualidade dos dados, da mitigação de vieses, da governança do ciclo de vida e da forma como os resultados são apresentados aos usuários. Trabalhos sobre documentação de datasets e IA centrada em dados reforçam a importância de curadoria, rastreabilidade e responsabilidade [Gebru et al. 2021, Jakubik et al. 2024]. Estudos sobre fairness evidenciam riscos de impactos discriminatórios e propõem estratégias de mitigação [Barocas and Selbst 2016, Mehrabi et al. 2021]. Por sua vez, pesquisas sobre IA centrada no humano, aprendizado ativo e débito técnico em sistemas de ML destacam a necessidade de supervisão humana, evolução incremental e arquiteturas sustentáveis [Amershi et al. 2019, Settles 2012, Sculley et al. 2015]. O presente trabalho conecta essas dimensões em um projeto aplicado de investigação financeira.

3. Diretrizes Propostas

A experiência do projeto permitiu organizar sete diretrizes para implantação de soluções de IA em investigação financeira. As Figuras 1, 2 e 3 sintetizam essas diretrizes e os principais componentes do arcabouço proposto.

D1 – Curadoria *data-centric*. O sistema deve priorizar qualidade, consistência e representatividade dos dados. No projeto, isso envolve ingestão de dados bancários anonimizados, padronização de formatos, deduplicação, validações estruturais e semânticas, enriquecimento cadastral e detecção automática de inconsistências, como duplicidades, incoerências de saldo e problemas de ordenação temporal.

D2 – Mitigação de vieses. A análise de vieses precisa ocorrer desde a preparação dos dados até a avaliação dos modelos. Foram realizadas análises exploratórias de desequilíbrios e experimentos com um simulador de dados sintéticos, denominado AMLBias, para avaliar robustez em cenários *out-of-distribution*. Essa estratégia ajuda a compreender como mudanças na distribuição dos dados afetam desempenho, confiabilidade e generalização.




Figura 1. Diretrizes 1 e 2 do projeto: abordagem *data-centric* para curadoria de dados e mitigação de vieses algorítmicos, com ênfase na qualidade dos dados, geração de dados sintéticos e avaliação de robustez e *fairness*.

D3 – Fluxos flexíveis e composição de modelos. A arquitetura deve permitir combinar regras heurísticas, modelos probabilísticos, algoritmos de grafos e técnicas de aprendizado de máquina. No projeto, detectores de repasses financeiros, transações em espécie, fragmentação e regras investigativas podem ser executados isoladamente ou combinados, com resultados integrados em painéis analíticos.

D4 – IA centrada no humano. Os modelos foram concebidos como instrumentos de apoio à decisão. Dashboards, tabelas dinâmicas, grafos de vínculos e análises temporais apresentam alertas interpretáveis, que devem ser validados por especialistas. Testes de usabilidade e validações com analistas reais orientaram a evolução das interfaces.

D5 – Incorporação de conhecimento especializado. O conhecimento dos investigadores foi usado na definição de tipologias, regras heurísticas, parâmetros de modelos e bases rotuladas. Por exemplo, detectores de repasses consideraram hipóteses como saldos líquidos próximos de zero, intensidade do volume financeiro e padrões temporais de movimentação.

D6 – Escalabilidade e processamento incremental. Como investigações podem

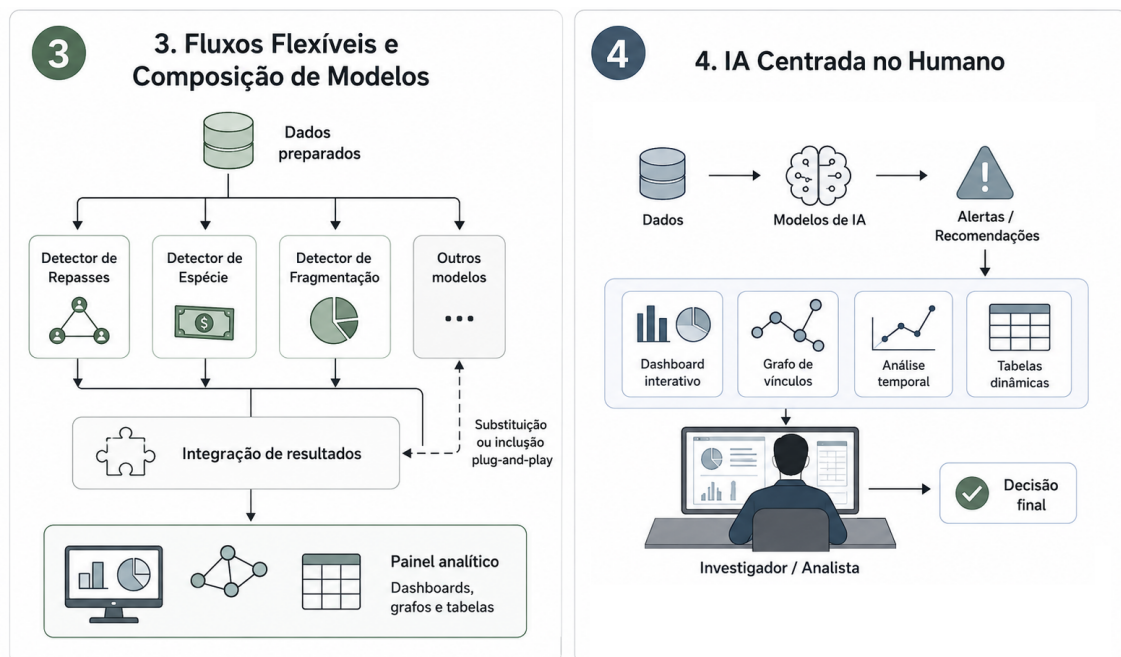


Figura 2. Diretrizes 3 e 4 do projeto: fluxos flexíveis e composição de modelos, além de IA centrada no humano, enfatizando integração de detectores, visualizações analíticas e suporte à decisão para investigadores.

envolver centenas de milhares de transações, foram adotadas estratégias de localidade, processamento intra-dia e inter-dias, paralelização e serviços compartilhados. A migração para arquitetura orientada a eventos, com mensageria, busca reduzir acoplamento e facilitar escalabilidade.

D7 – Aprendizado contínuo com *feedback* humano. Validações de alertas, correções, marcações de falsos positivos e classificações de padrões suspeitos devem retroalimentar regras e modelos. Esse ciclo aproxima o comportamento do sistema das necessidades reais dos especialistas, aumentando utilidade prática e confiabilidade.

4. Resultados Iniciais

Os resultados iniciais indicam que a solução desenvolvida possui potencial prático para apoiar investigações financeiras, especialmente na identificação de padrões suspeitos, priorização de análises e organização de evidências. Até o momento, os modelos vêm sendo treinados e avaliados sobre 226.307 registros de transações bancárias anonimizadas, combinando regras investigativas, modelos probabilísticos, análise temporal e técnicas de grafos.

De forma geral, a solução demonstrou capacidade de consolidar grandes volumes de dados transacionais, estruturar informações dispersas e apresentar alertas interpretáveis para apoiar o trabalho dos investigadores. A arquitetura modular também se mostrou relevante, pois permite executar regras de forma independente, incluir novos detectores, reexecutar módulos específicos e comparar diferentes estratégias de análise. Nesse sentido, já foram consolidadas saídas de cinco detectores analíticos, incluindo três modelos de fragmentação, um detector de transações em espécie e um detector de repasses financeiros.

Lições Aprendidas. A principal lição é que a qualidade dos dados determina



Figura 3. Diretrizes 5, 6 e 7 do projeto: incorporação do conhecimento dos especialistas nos modelos, uso de localidade e processamento incremental para *Big Data*, e aprendizado contínuo com *feedback* humano.

boa parte do sucesso da solução. Em investigações financeiras, inconsistências, duplicidades e heterogeneidade de fontes podem comprometer modelos sofisticados. Assim, validação, integração, documentação e enriquecimento dos dados devem ser tratados como componentes centrais do sistema. Uma segunda lição é que especialistas do domínio são indispensáveis. Regras aparentemente simples, como valores arredondados, proximidade de limites ou padrões de repasse, dependem de interpretação contextual. O envolvimento dos investigadores aumenta a relevância dos alertas, reduz falsos positivos e fortalece a confiança na ferramenta.

Também se observou que flexibilidade arquitetural, rastreabilidade e auditoria são requisitos operacionais. É necessário saber qual regra foi executada, quando, com quais parâmetros, qual resultado foi produzido e como o especialista interpretou a saída. Sem esse histórico, torna-se difícil depurar modelos, justificar alertas ou evoluir o sistema de modo seguro. Por fim, a experiência evidenciou que sistemas de IA para investigação financeira devem ser tratados simultaneamente como modelos analíticos, produtos de software e infraestruturas escaláveis. Interpretabilidade, controle humano, processamento incremental e aprendizado contínuo não são funcionalidades acessórias, mas condições para adoção efetiva em ambientes sensíveis.

5. Conclusão e Trabalhos Futuros

Este artigo apresentou diretrizes, resultados iniciais e lições aprendidas em um projeto real de ciência de dados aplicado à investigação financeira no contexto da Polícia Civil de Pernambuco. As evidências preliminares sugerem que a combinação de curadoria *data-centric*, modelagem híbrida, participação de especialistas, arquitetura modular e *feedback* humano pode apoiar a organização de evidências, a priorização de alertas e a rastreabilidade do processo investigativo.

Como trabalhos futuros, pretende-se realizar estudos de usabilidade e utilidade com investigadores e analistas, de modo a avaliar a efetividade das interfaces desenvolvidas, a facilidade de uso dos fluxos analíticos, a interpretabilidade dos alertas e a contribuição efetiva da ferramenta para a tomada de decisão. Além disso, pretende-se avaliar a esca-

labilidade da solução, considerando diferentes volumes de transações, múltiplos casos simultâneos, tempo de execução dos detectores, consumo de recursos computacionais e desempenho da arquitetura em cenários de maior complexidade.

Agradecimentos

Os autores agradecem o apoio financeiro da Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE), processo nº APQ-0080-1.03/25.

Referências

- Akoglu, L., Tong, H., and Koutra, D. (2015). Graph based anomaly detection and description: a survey. *Data Mining and Knowledge Discovery*, 29(3):626–688.
- Amershi, S., Weld, D., Vorvoreanu, M., Fournery, A., Nushi, B., Collisson, P., Suh, J., Iqbal, S. T., Bennett, P. N., Inkpen, K., Teevan, J., Kikin-Gil, R., and Horvitz, E. (2019). Guidelines for human-ai interaction. In *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, pages 1–13. ACM.
- Barocas, S. and Selbst, A. D. (2016). Big data’s disparate impact. *California Law Review*, 104(3):671–732.
- Bolton, R. J. and Hand, D. J. (2002). Statistical fraud detection: A review. *Statistical Science*, 17(3):235–255.
- Geburu, T., Morgenstern, J., Vecchione, B., Vaughan, J. W., Wallach, H., Daumé III, H., and Crawford, K. (2021). Datasheets for datasets. *Communications of the ACM*, 64(12):86–92.
- Hernandez Aros, L., Bustamante Molano, L. X., Gutierrez-Portela, F., Moreno Hernandez, J. J., and Rodríguez Barrero, M. S. (2024). Financial fraud detection through the application of machine learning techniques: a literature review. *Humanities and Social Sciences Communications*, 11:1130.
- Holzinger, A. (2016). Interactive machine learning for health informatics: when do we need the human-in-the-loop? *Brain Informatics*, 3(2):119–131.
- Jakubik, J., Vössing, M., Köhl, N., Walk, J., and Satzger, G. (2024). Data-centric artificial intelligence. *Business & Information Systems Engineering*, 66(4):507–515.
- Mehrabi, N., Morstatter, F., Saxena, N., Lerman, K., and Galstyan, A. (2021). A survey on bias and fairness in machine learning. *ACM Computing Surveys*, 54(6):1–35.
- Pang, G., Shen, C., Cao, L., and van den Hengel, A. (2021). Deep learning for anomaly detection: A review. *ACM Computing Surveys*, 54(2):1–38.
- Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., Ebner, D., Chaudhary, V., Young, M., Crespo, J.-F., and Dennison, D. (2015). Hidden technical debt in machine learning systems. In *Advances in Neural Information Processing Systems*, volume 28, pages 2503–2511.
- Settles, B. (2012). *Active Learning*. Synthesis Lectures on Artificial Intelligence and Machine Learning. Morgan & Claypool Publishers.
- Shneiderman, B. (2020). Human-centered artificial intelligence: Reliable, safe & trustworthy. *International Journal of Human–Computer Interaction*, 36(6):495–504.