



FINANCE TECH
BOOST

Inteligência Artificial e Análise de Dados

Liderando as Finanças do Futuro

Thiago Diogo e Cleber Brandão

Disclaimer

A Responsabilidade pela idoneidade, originalidade e licitude dos conteúdos didáticos apresentados é do especialista.

AGENDA



01

**Introdução + Contexto de IA +
Panorama atual das fraudes**

02

Por que IA? Por que agora?

03

IA e ML aplicados a prevenção a fraudes

04

Arquitetura típica e abordagens

05

Demonstração

06

Estratégias de implementação

Prazer, eu sou Thiago



Founder & CEO

DURANIUM

Staff, Technical Solutions Consultant
Privacy Sandbox



Director

Security, Privacy and Platform



Chief Technology Officer (CTO)
Security, Privacy and Platform



Cybersecurity Researcher
AWS Cloud Security & Compliance



NEW YORK UNIVERSITY



**Universidade
Federal
Fluminense**

Ciência da Computação e
Mestrado em Tecnologia



**Massachusetts
Institute of
Technology**

Especialização em
Criptografia e Segurança



Especialização em
Security Engineering



Especialização em
Privacy Engineering



© 2015 Pearson Education, Inc. or its affiliate(s). All rights reserved. No part of this publication may be reproduced, stored in a retrieval system, or transmitted, in any form or by any means, electronic, mechanical, photocopying, recording, or by any information storage or retrieval system, without prior written permission from Pearson Education, Inc. or its affiliate(s).

Introdução

Cenário das fraudes no Brasil

O Brasil ocupa posição de destaque mundial em fraudes financeiras. Segundo dados da Federação Brasileira de Bancos (FEBRABAN), as **tentativas de fraude cresceram 73% em 2023**, representando perdas de mais de R\$ 2,9 bilhões ao sistema financeiro.

Principais vetores de fraude:

- Engenharia social (40% dos casos)
- Vazamento de dados (25%)
- Ataques cibernéticos diretos (20%)
- Fraudes em cartões (15%)


Fonte: FEBRABAN - Relatório de Tecnologia Bancária 2023



Introdução

Cenário das fraudes no Brasil

Quantidade de Tentativas de Fraude - Últimos 12 meses



Uma tentativa a cada 2,2 segundos



Fonte: Serasa Experian

A Responsabilidade pela idoneidade, originalidade e licitude dos conteúdos didáticos apresentados é do especialista.

O movimento dos bancos

Como e para o que os bancos estão usando IA?

Valores percebidos a partir da aplicação de IA¹



Redução de custos



Aumento na velocidade da execução de tarefas rotineiras



Aumento na detecção e prevenção de fraudes



Maior apoio para análise de dados



Melhora na personalização dos serviços



Eficiência na previsão de tendências e comportamentos



Redução no tempo de resposta aos clientes



Aumento na satisfação do cliente

Casos de uso de IA aplicáveis à cibersegurança, prevenção à fraude ou à lavagem de dinheiro e estágio de adoção dos bancos participantes para cada caso¹ (percentual dos bancos)

Cibersegurança, para proteger sistemas e dados contra ataques cibernéticos

Não explorado

20%

Em exploração

10%

Em implementação

70%

Biometria, para reconhecimento de voz, face e outras características biométricas

30%

10%

60%

Visão computacional, para analisar e interpretar imagens e vídeos

35%

25%

40%

Deteção de fraude e lavagem de dinheiro, para identificar transações suspeitas e atividades ilícitas

20%

-

80%

Know Your Customer (KYC) e onboarding, para automatizar e otimizar a verificação de identidade de clientes

15%

20%

65%

FEBRABAN

Federação Brasileira de Bancos

Os bancos entendem que IA pode ser o habilitador de jornadas seguras e simples

FEBRABAN


Federação Brasileira de Bancos

Alidade e litude dos conteúdos didáticos apresentados é do

especialista.

Por que IA? Por que agora?


Por que IA é chave para mudar esse cenário?



Porém, cuidado!

AI $\neq$ GenAI

Porém, cuidado!



¹LLM is an intersection of DL and NLP

²Conversational AI is a combination of ML and NLP. It may include DL and LLM, but that isn't always the case.

O Que São LLMs?

- Modelos de linguagem de grande porte (ex: GPT-4, CodeLlama).
- Usados para gerar textos, respostas e código.
- Treinados com grandes volumes de dados.

O Problema: Alucinações

- Falta de conexão com uma base de dados atual
- Geração probabilística, não baseada em fatos
- Ausência de mecanismos de validação interna

Riscos Adicionais da IA

- Vieses nos dados e decisões injustas.
- Uso malicioso da IA para ataques ou fraudes.
- Exposição de dados sensíveis (vazamentos).
- Falta de transparência e explicabilidade.
- Automação excessiva sem supervisão.
- Responsabilidade difusa em decisões automatizadas.
- Violação de privacidade e conformidade regulatória.

Formas de Mitigação (Visão Geral)

- Retrieval-Augmented Generation(RAG).
IA consulta bases confiáveis antes de responder.
Reduz chance de inventar respostas
- Auto-refinamento (self-checking).
IA avalia e revisa sua própria resposta.
Detecta inconsistências antes da execução.
- Fine-tuning supervisionado.
Reeducação do modelo com dados corretos.
Redução de pacotes inventados.
Possível impacto na criatividade do código.

Boas Práticas Complementares

- Nunca confiar cegamente no código gerado por IA.
- Verificar pacotes em fontes oficiais.
- Usar ferramentas de análise de dependências.
- Implementar validação automatizada.
- Avaliar explicabilidade e fonte dos dados usados.

Conclusões

- IA é poderosa, mas pode ser enganada.
- Riscos como alucinações e uso malicioso são reais.
- Mitigação depende de práticas seguras e supervisão.

Links e materiais de estudo

- MIT AI Risk Repository
<https://airisk.mit.edu/>
- A Comprehensive Analysis of Package Hallucinations by Code Generating LLMs
<https://arxiv.org/html/2406.10279v1>
Códigos para prática: <https://github.com/Spracks/PackageHallucination>
- Garak LLM Vulnerability Scanner (nvidia)
<https://garak.ai/>



● IA e ML aplicados a prevenção a fraudes

O contexto de dados

Entendendo os dados

O volume de dados
é **assustador**
enquanto pouca
sabedoria é
alcançada



O que temos de dados disponíveis?

Entendendo os dados

O cliente...

dados de identificação, idade, cidade do cadastro, tempo de cadastro, cidade da rotina de uso, data do cadastro, tempo de vida dentro do sistema, quantidade de transações aprovadas feitas antes, tempo de vida da senha, usou MFA ou não, etc

A transação...

data, hora, localização, valor, método de pagamento, detalhes do produto/serviço, descontos aplicados, uso de pontos de fidelidade, de qual dispositivo, IP de origem, sistema operacional, histórico de pedidos, frequência, etc

O chargeback...

motivo, data da transação e da solicitação, valores contestados, resultado de processos anteriores, tempo entre transação e solicitação, frequência de solicitações, consistência de códigos de chargeback, discrepância entre valor contestado e transação, etc

E muito mais:

O dispositivo, os dados do contexto do pagamento, os dados do produto/serviço,

Digite seu Tópico aqui

Entendendo os dados

Exemplos hipotéticos de **correlações** e **padrões**:

Em 95% das fraudes, o chargeback foi solicitado em exatos **12 min** após a transação...

Em nenhum dos chargebacks fraudulentos, o usuário **entrou em contato** via central de atendimento tentando resolver o problema antes

Todas as transações legítimas foram feitas em até **100km do local habitual** do usuário nos últimos 2 meses






Detectar anomalias


Identificar padrões ou comportamentos incomuns que se desviam do que é considerado normal e esperado, sinalizando uma possível atividade fraudulenta




OK, mas como encontrar anomalias?






OK, mas como encontrar anomalias?




OK, mas como encontrar anomalias?



OK, mas como encontrar anomalias?



Modelagens de IA e ML



Aplicando em Prevenção a Fraudes



Aplicando em Prevenção a Fraudes



Detecção de Anomalias

Identifica padrões que desviam significativamente do comportamento normal:

- One-Class SVM: Para dados com poucas amostras fraudulentas
- Isolation Forest: Eficaz para datasets grandes e multi-dimensionais
- Autoencoders: Redes neurais que identificam reconstruções anômalas



Análise Comportamental

Monitora padrões de uso individual:

- Horários habituais de transações
- Localização geográfica
- Valores típicos de transferências
- Dispositivos utilizados




Processamento de Linguagem Natural (NLP)

Analisa comunicações para identificar tentativas de fraude:


- Detecção de phishing em e-mails
- Análise de mensagens suspeitas
- Identificação de scripts automatizados

Arquitetura Típica




Canais de **aquisição**
de transações

Arquitetura Típica




Um **Score de Risco** é
calculado com base
na abordagem
*(regras ou
comportamento)*

Arquitetura Típica




Com Base no Score,
uma decisão é
tomada


Arquitetura Típica



Sequência transacional



Sequência transacional



Calculando o risco de uma transação

Regras estáticas

Conjunto fixo de condições pré-definidas baseadas em regras if-then

X

Modelos adaptativos

Algoritmos de ML que aprendem e se ajustam automaticamente aos dados

Abordagens

Aspecto	Regras Estáticas	Modelos Adaptativos
Flexibilidade	✗ Baixa - requer alteração manual	✓ Alta - auto-ajuste contínuo
Implementação	✓ Simples e rápida	✗ Complexa, requer expertise em ML
Manutenção	✗ Alta - revisão manual constante	✓ Baixa - aprendizado automático
Deteção de Novos Padrões	✗ Não detecta automaticamente	✓ Identifica padrões emergentes
Precisão Inicial	⚠ Boa para fraudes conhecidas	✓ Pode ser superior com dados suficientes
Escalabilidade	⚠ Limitada pela complexidade das regras	✓ Escala com volume de dados
Taxa de Falsos Positivos	✗ Pode ser alta sem ajustes	✓ Otimização contínua
Adaptação a Mudanças	✗ Manual e lenta	✓ Automática e rápida
Dependência de Dados	✓ Baixa	✗ Alta - requer grandes volumes

Motores de Antifraude

FICO

RSA

 LexisNexis®

 **sas**

feedzai

 **SEON**

 **BioCatch**

 **sift**

OneTrust
PRIVACY, SECURITY & GOVERNANCE

**Comply
Advantage**


ClearSale

cpqc

 **Fraudio**

 **HAWK:AI**

 **Signifyd**

IDoLOGY
a GBG company

 **SHIELD**

NICE

 **INETCO**
Every transaction tells a story

**data
rudder**

 **FraudAverse**
x
IBM

 **authcube**

No mercado, existem diversas plataformas chamadas motores de antifraudes – a depender do seu negócio, vale considerar

The logo for Finance Tech Boost is centered within a large, light blue circle. It consists of the words "FINANCE TECH" in a white, uppercase, sans-serif font, positioned above the word "BOOST" in a larger, bold, blue, uppercase, sans-serif font. Two thin white horizontal lines frame the text, one above "FINANCE TECH" and one below "BOOST".

FINANCE TECH
BOOST

Demonstração

Demonstração



Objetivos da Demo

- **Implementar 4 algoritmos** diferentes de detecção de fraudes
- **Comparar** performance entre modelos supervisionados e não-supervisionados
- **Simular** um ambiente bancário real com scoring em tempo real
- **Visualizar métricas de negócio** relevantes

Dataset Realista

- **50.000 transações** simulando padrões brasileiros
- **2% taxa de fraude** (similar ao mercado real)
- **11 features** incluindo valor, horário, canal, dispositivo, localização
- **Padrões comportamentais** distintos entre transações legítimas e fraudulentas

Stack Tecnológico

- **Python** + Scikit-learn + Pandas
- **Modelos:** Random Forest, Logistic Regression, Isolation Forest, One-Class SVM
- **Técnicas:** SMOTE para balanceamento, Feature Engineering, Cross-validation
- **Visualização:** Matplotlib, Seaborn, Plotly (interativo)

```
anti-fraudes-exemplo - v1.ipynb
File Edit View Insert Runtime Tools Help







Commands | + Code | + Text

Show code
Bibliotecas importadas com sucesso!






Show code
Dataset criado com 50000 transações
Taxa de fraude: 2.00%
Distribuição de classes:
is_fraud
0.0    49000
1.0     1000
Name: count, dtype: int64

Show code
=== INFORMAÇÕES DO DATASET ===
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 50000 entries, 0 to 49999
Data columns (total 14 columns):
#   Column              Non-Null Count  Dtype
---
```


Comportamento



Comportamento



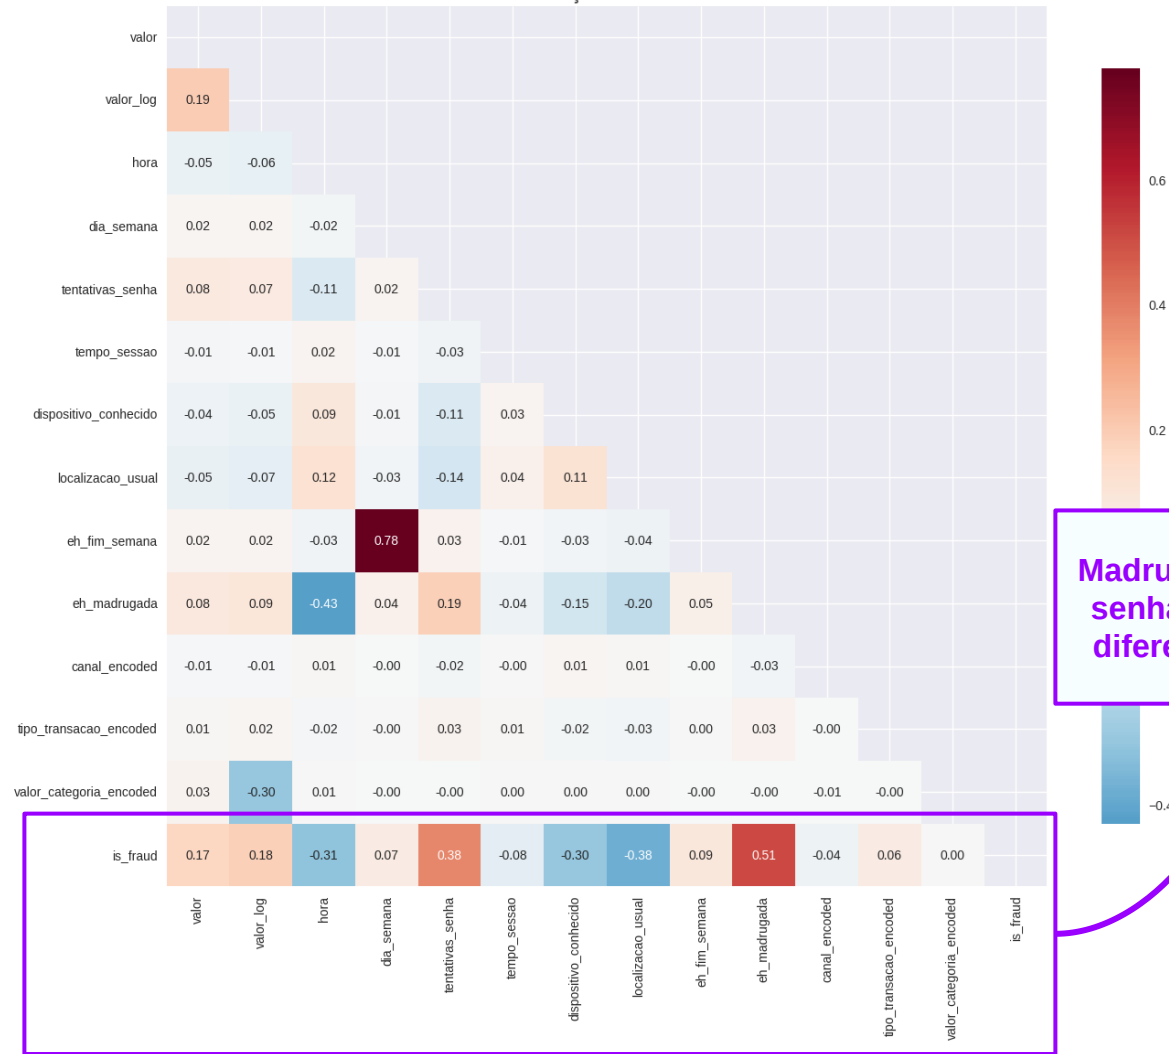
Matriz de Correlação - Features vs Fraude



O que
influencia a
fraude?

Onde se
concentra
nosso risco
transacional?

Matriz de Correlação - Features vs Fraude




O que
influencia a
fraude?


Onde se
concentra
nosso risco
transacional?

O que
influencia a
fraude?


Onde se
concentra
nosso risco
transacional?







E como avaliar os resultados?



E como avaliar os resultados?



E qual modelo
de IA/ML
performou
melhor nesse
exemplo?



Random forest com
melhor performance
(F1-Score)



Estratégias de implementação

Estratégia de implementação

Curso: Inteligência Artificial e Análise de Dados

Começar Pequeno

Investir em Pessoas


Estratégia de implementação

Curso: Inteligência Artificial e Análise de Dados




Estratégia de implementação

Curso: Inteligência Artificial e Análise de Dados



Estratégia de implementação

Curso: Inteligência Artificial e Análise de Dados



The logo consists of the words "FINANCE TECH" in a white, uppercase, sans-serif font, positioned above the word "BOOST" in a larger, bold, blue, uppercase, sans-serif font. Two thin white horizontal lines are placed above and below the text.

FINANCE TECH
BOOST

Muito
Obrigado!



Contato



Thiago Diogo



thiago@duranium.io



<https://www.linkedin.com/in/thiagodiogo>



SCAN ME