

Trilhas de Auditoria para Detecção de Fraudes Envolvendo Servidores Públicos da Saúde

Marco Túlio Dutra^{1,2}, Lucas G. L. Costa¹,
Gabriel P. Oliveira¹, Mariana O. Silva¹, Gisele L. Pappa¹

¹Universidade Federal de Minas Gerais (UFMG) – Belo Horizonte, MG – Brasil

²Universidade Federal de Ouro Preto (UFOP) – Ouro Preto, MG – Brasil

marco.dutra@aluno.ufop.edu.br, lucas-lage@ufmg.br
{gabrieloliveira,mariana.santos,glpappa}@dcc.ufmg.br

Abstract. *Identifying and preventing fraud in the public sector, especially in the context of healthcare, are crucial issues to guarantee the integrity of resources and the quality of services provided to the population. This paper proposes an approach based on audit trail modeling to identify and rank fraud alerts involving public health employees. By analyzing suspicious patterns in public employee records, we propose a ranking system that directs audit efforts to cases with the highest probability of fraud. The results obtained using our approach provide essential information that simplifies the subsequent manual investigation step carried out by auditors.*

Resumo. *Identificar e prevenir fraudes no setor público, especialmente no contexto da saúde, são questões cruciais para garantir a integridade dos recursos e a qualidade dos serviços prestados à população. Este artigo propõe uma abordagem baseada em modelagem de trilhas de auditoria para identificar e ranquear alertas de fraude envolvendo servidores públicos da saúde. Através da análise de padrões suspeitos nos registros dos servidores públicos, é proposto um sistema de ranqueamento que direcione os esforços de auditoria para os casos com maior probabilidade de fraude. Os resultados obtidos utilizando nossa abordagem fornecem informações essenciais que simplificam a etapa posterior de investigação manual realizada por auditores.*

1. Introdução

A identificação e prevenção de fraudes no setor público, especialmente no contexto da saúde, são questões de extrema importância para garantir a integridade dos recursos e a qualidade dos serviços oferecidos à população [Neubauer et al. 2022]. A fraude no setor público pode assumir diversas formas, desde desvio de recursos financeiros até manipulação de dados e informações [Kratcoski 2018, Pereira et al. 2022, Silva et al. 2023]. Essas práticas fraudulentas não apenas representam um desperdício de recursos públicos, mas também podem comprometer o acesso e a qualidade dos serviços de saúde disponíveis para os cidadãos.

No contexto específico da saúde, onde a demanda por serviços é frequentemente alta e os recursos são limitados, a eficiência na gestão dos recursos humanos é crucial. Nesse sentido, o Cadastro Nacional de Estabelecimentos de Saúde (CNES)¹ foi criado

¹Cadastro Nacional dos Estabelecimentos de Saúde (CNES): <https://cnes.datasus.gov.br/>

em 1999 com o objetivo de concentrar todos os estabelecimentos de saúde (públicos, conveniados e privados) que realizam qualquer tipo de serviço de atenção à Saúde no Brasil. Esse sistema é, portanto, uma importante ferramenta de apoio para a tomada de decisão e planejamento de ações por parte dos gestores públicos, possibilitando uma gestão eficiente dos recursos financeiros [Pelissari 2019].

No entanto, mesmo com sistemas como o CNES em vigor, o setor da saúde ainda enfrenta desafios significativos relacionados à gestão de recursos humanos e à integridade dos dados [Rocha et al. 2018]. Problemas como a prática de cargas horárias excessivas e deslocamentos consideráveis entre estabelecimentos de saúde podem conflitar com o cumprimento da carga horária em todos os estabelecimentos onde um profissional atue, indicando possíveis casos de fraude. Essas práticas podem configurar violações éticas e legais, incluindo o desvio de recursos públicos e a improbidade administrativa.

Diante desse panorama, é imprescindível o desenvolvimento de estratégias eficazes para a detecção e prevenção de fraudes no setor público da saúde, visando assegurar a transparência e a eficiência na gestão dos recursos destinados à saúde [Kratcoski 2018, Kumaraswamy et al. 2024]. No contexto brasileiro, a crescente demanda por serviços de saúde e os desafios enfrentados na gestão eficaz dos recursos públicos ressaltam a necessidade urgente de abordagens inovadoras para combater a fraude e a corrupção. Nesse sentido, diversos estudos têm se dedicado à análise da confiabilidade dos dados do Cadastro Nacional dos Estabelecimentos de Saúde (CNES) e seu papel crucial na gestão de equipamentos médico-hospitalares [Rocha et al. 2018, Pelissari 2019].

Portanto, este trabalho propõe uma abordagem baseada em modelagem de trilhas de auditoria para identificar e ranquear alertas de fraude envolvendo servidores públicos da saúde. Trilhas de auditoria são sequências de passos para identificar tipos específicos de irregularidades em dados governamentais [Costa et al. 2023, Oliveira et al. 2023]. Dessa forma, através da análise de padrões suspeitos nos registros de atividades e deslocamentos dos servidores públicos, em parceria com o Ministério Público do Estado de Minas Gerais (MPMG), é proposto um sistema de ranqueamento de alertas para direcionar os esforços de auditoria para os casos com maior probabilidade de fraude.

Este artigo está estruturado da seguinte forma. A Seção 2 discute os trabalhos relacionados, enquanto a Seção 3 descreve a fonte de dados considerada no trabalho. Já a Seção 4 apresenta a metodologia utilizada na construção das trilhas de auditoria e no ranqueamento. A Seção 5 caracteriza os resultados das trilhas e do ranqueamento, apresentando exemplos reais onde foram gerados alertas de fraude. Finalmente, a Seção 6 conclui este trabalho, além de descrever as possíveis limitações e sugerir trabalhos futuros.

2. Trabalhos Relacionados

O combate a fraudes no setor público é uma prioridade global, sendo essencial para garantir a integridade das instituições governamentais [Silva et al. 2020]. Um aspecto em comum dos trabalhos que abordam essa tarefa é a necessidade de lidar com grandes volumes de dados, geralmente utilizando técnicas de inteligência artificial e aprendizado de máquina para processá-los [Mongwe and Malan 2020, Handoko and Rosita 2022]. No contexto brasileiro, estudos recentes investigam os procedimentos de detecção de fraudes e o impacto das tecnologias na consciência anti-fraude no setor público [Silva et al. 2020]. Além disso, [Oliveira et al. 2021] analisam a eficácia das ferramentas da Controladoria

Geral da União (CGU) no combate a fraudes durante a pandemia de COVID-19.

As licitações públicas representam um importante ponto de detecção de fraudes no Brasil, sendo alvo de diversos estudos que propõem soluções para otimizar a investigação. Por exemplo, [Brandão et al. 2024] propõem um *pipeline* semiautomático para detecção de fraudes em licitações a partir de técnicas de qualidade de dados e aprendizado de máquina. Outros estudos utilizam outras técnicas, incluindo análise de redes sociais [Pereira et al. 2022, Costa et al. 2023], heurísticas [Oliveira et al. 2022] e análises estatísticas [Braz et al. 2023, Silva et al. 2023].

Outras áreas da administração pública, como a saúde, também têm recebido atenção no contexto do governo eletrônico [Neubauer et al. 2022, Domingues et al. 2021, Kumaraswamy et al. 2024]. [Kratcoski 2018] discute que o setor público de saúde apresenta inúmeras oportunidades para a ocorrência de fraudes e corrupção, o que muitas vezes desafia a eficácia da fiscalização em prevenir tais crimes, tanto por parte dos prestadores de serviços quanto dos beneficiários. No cenário brasileiro, muitos estudos têm se dedicado a analisar a confiabilidade dos dados do Cadastro Nacional dos Estabelecimentos de Saúde (CNES) e seu papel fundamental na gestão de equipamentos médico-hospitalares [Rocha et al. 2018, Pelissari 2019].

[Rocha et al. 2018] compararam a confiabilidade de um grupo de dados registrados junto às bases secundárias do CNES. Apesar de serem identificados casos de inconsistência, no geral, os resultados indicaram para uma boa confiabilidade dos dados do Cadastro Nacional dos Estabelecimentos de Saúde, quanto às categorias comparadas. De forma similar, o estudo realizado por [Pelissari 2019] revelou que o sistema CNES é uma ferramenta confiável e fundamental para uma gestão eficaz e eficiente. No entanto, é necessária a conscientização dos gestores em mantê-lo atualizado, e em garantir a precisão das informações inseridas no sistema.

Apesar da existência de trabalhos que analisam o setor da saúde, ainda há uma escassez de estudos que se concentrem especificamente na detecção de fraudes nessa área. A falta de investigação científica neste contexto específico revela uma oportunidade de preencher esta lacuna de conhecimento, especialmente considerando que fraudes e irregularidades podem afetar a qualidade e disponibilidade dos serviços de saúde. Portanto, este trabalho busca agregar conhecimento nesta área ao propor abordagens para identificar alertas de fraude envolvendo servidores públicos na área da saúde.

3. Cadastro Nacional de Estabelecimentos de Saúde (CNES)

O Cadastro Nacional de Estabelecimentos de Saúde (CNES) é o principal sistema de informação do Ministério da Saúde para cadastrar e manter informações sobre todos os estabelecimentos de saúde no Brasil, incluindo as redes pública, conveniada e privada. Tal sistema tem como objetivo cadastrar e atualizar informações sobre os estabelecimentos de saúde, disponibilizar dados para outros sistemas, fornecer informações à sociedade sobre a disponibilidade de serviços, e apoiar a tomada de decisão, planejamento e programação na área da saúde. O CNES está disponível publicamente para consultas² e downloads.³

De forma geral, o CNES contém informações diversas sobre profissionais e esta-

²<https://cnes.datasus.gov.br/pages/consultas.jsp>

³<https://cnes.datasus.gov.br/pages/downloads/arquivosBaseDados.jsp>

belecimentos de saúde. Em relação aos profissionais, ele disponibiliza informações como nome, Cartão Nacional de Saúde (CNS), vínculos, carga horária e ocupações (de acordo com a Classificação Brasileira de Ocupações – CBO). Já sobre os estabelecimentos, é possível obter a localização, nome fantasia, razão social, Cadastro Nacional da Pessoa Jurídica (CNPJ), tipo de gestão, natureza jurídica, dentre outras.

4. Metodologia

Esta seção detalha a metodologia empregada para identificar possíveis fraudes na conduta dos servidores da saúde. Suas principais etapas são fundamentadas na construção de trilhas de auditoria, cujo conceito foi introduzido na Seção 1. Essas etapas são delineadas na Figura 1 e incluem: a definição das trilhas (Seção 4.1), o pré-processamento dos dados (Seção 4.2), a modelagem formal das trilhas (Seção 4.3), e um processo de ranqueamento para consolidar os alertas de fraude gerados por cada trilha (Seção 4.4). Cada uma dessas etapas é detalhada nas próximas seções.

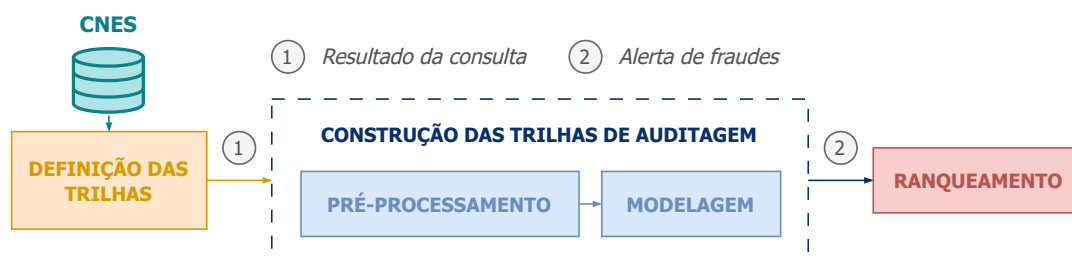


Figura 1. Metodologia para alerta de fraudes envolvendo servidores públicos.

4.1. Definição das Trilhas

Neste trabalho, foram definidas em conjunto com especialistas do Ministério Público de Minas Gerais uma série de trilhas para gerar alertas que podem indicar possíveis fraudes envolvendo servidores públicos da área da saúde. As trilhas foram elaboradas para abranger uma variedade de cenários e comportamentos suspeitos, levando em consideração a complexidade e diversidade das atividades desempenhadas pelos profissionais de saúde. A Tabela 1 apresenta as cinco trilhas definidas para este trabalho, cada uma englobando diferentes aspectos e informações relevantes aos vínculos e atividades dos servidores.

É importante destacar que a análise de uma trilha de forma isolada não necessariamente sugere a ocorrência de fraude. Por exemplo, a trilha T_3 tem como objetivo identificar servidores da saúde com múltiplos vínculos empregatícios no mesmo mês. De acordo com a legislação em vigor no Brasil, essa situação não é necessariamente ilícita por si só. No entanto, ao combinar esse alerta com outros gerados por diferentes trilhas, é possível identificar padrões mais complexos que podem indicar a necessidade de investigação por parte de especialistas. Em outras palavras, a elaboração e execução das trilhas não substituem a análise manual desses casos, mas aprimoram e agilizam o trabalho dos auditores, direcionando seus esforços para áreas com maior potencial de irregularidades.

4.2. Pré-processamento

Considerando as trilhas de auditoria de interesse, o processo de pré-processamento se inicia após a obtenção dos resultados da consulta na base do CNES. Em seguida, é definido um campo que informa o tipo de vínculo dos servidores. Tal processamento é

Tabela 1. Definição das trilhas de auditoria.

#	Nome da Trilha	Regra
T_1	Distância percorrida elevada	Verificar os servidores da saúde que percorrem uma grande distância, semanalmente, entre as cidades em que trabalham.
T_2	Expediente muito longo	Verificar os servidores da saúde que possuem um expediente muito longo.
T_3	Múltiplos vínculos públicos	Verificar os servidores da saúde que possuem múltiplos vínculos públicos no mesmo mês.
T_4	Número elevado de vínculos empregatícios	Verificar os servidores da saúde que possuem um número elevado de vínculos empregatícios no mesmo mês.
T_5	Carga horária de trabalho semanal elevada	Verificar os servidores da saúde que possuem uma carga horária de trabalho semanal muito elevada, levando em conta o total de horas trabalhadas e uma estimativa do tempo de deslocamento entre as cidades.

realizado a partir do campo *natureza jurídica*, que armazena códigos baseados na Tabela de Natureza Jurídica do Instituto Brasileiro de Geografia e Estatística (IBGE).⁴ A partir desses códigos, é possível classificar o tipo de vínculo do servidor entre público e privado.

Além disso, é realizado o cálculo da máxima distância entre um par de cidades dentre aquelas em que cada servidor atua. Para isso, é utilizada a Open Source Routing Machine (OSRM),⁵ uma ferramenta que permite calcular rotas entre diferentes localidades. Essa medida é essencial, uma vez que a base de dados fornece informações sobre as cidades em que cada servidor trabalha durante cada mês, mas não inclui detalhes sobre a rotina semanal ou as rotas específicas percorridas por eles.

No entanto, devido à falta de dados detalhados sobre as rotas semanais dos servidores, o pré-processamento utiliza uma abordagem simplificada. Nesse sentido, para estimar a distância semanal percorrida por cada servidor, considera-se o cenário que mais beneficia o servidor, assumindo que a rota entre todas as cidades seja a rota entre as duas mais distantes. Embora essa simplificação possa subestimar a distância real percorrida, permite uma análise inicial das trilhas de auditoria com base em informações disponíveis, ajudando a identificar possíveis casos de irregularidades na atuação dos servidores da saúde.

4.3. Modelagem das Trilhas

Nesta seção, é apresentada a modelagem das trilhas de auditoria, bem como os atributos necessários para a execução de cada uma. A definição das trilhas é fundamentada na teoria dos conjuntos, conforme ilustrado na Figura 2. A modelagem utiliza três conjuntos base que representam as entidades de interesse: Profissional (P), Mês (M) e Ocupação (O). A seguir, são detalhados tais conjuntos e suas respectivas definições formais.

- $P = \{p \mid p \in \text{Profissionais}\}$ é o conjunto de todos os profissionais presentes na base do CNES, incluindo aqueles que trabalham nas redes pública e privada.
- $O = \{o \mid o \in \text{Ocupações}\}$ é o conjunto de todas as ocupações exercidas pelos servidores da saúde (e.g., médico cardiologista, enfermeiro, fisioterapeuta).

⁴<https://concla.ibge.gov.br/estrutura/natjur-estrutura/natureza-juridica-2021>

⁵OSRM: <https://project-osrm.org/>

- $M = \{m \mid m \in [01/2015, 10/2023]\}$ é o conjunto de todos os meses compreendidos no intervalo de janeiro de 2015 a outubro de 2023.

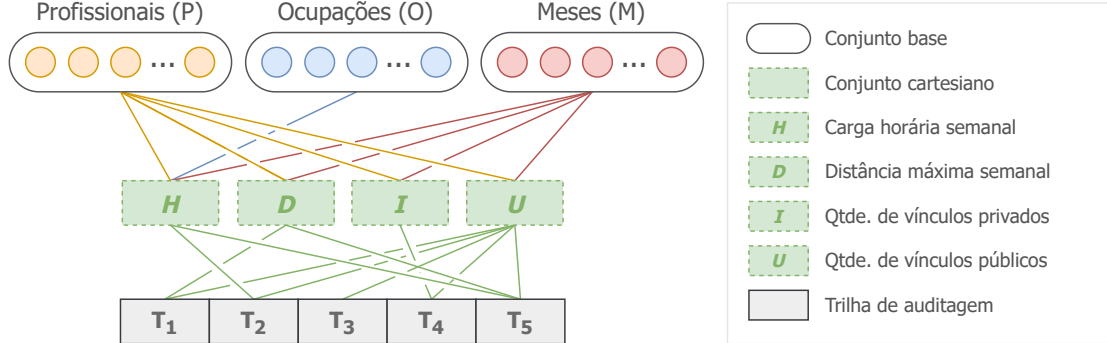


Figura 2. Modelagem das trilhas de auditoragem baseada na teoria dos conjuntos.

A partir do produto cartesiano dos conjuntos base, são criados quatro novos conjuntos denominados *conjuntos cartesianos*. Tais conjuntos representam diferentes atributos das entidades carga horária semanal (H), distância máxima semanal (D), quantidade de vínculos privados (I) e quantidade de vínculos públicos (U). A definição formal de cada uma é apresentada a seguir.

- $H = P \times M \times O = \{h_{pmo} \mid h_{pmo} \in \mathbb{R}^+ \wedge p \in P \wedge m \in M \wedge o \in O\}$ é conjunto com as cargas horárias semanais que o profissional p trabalhou durante o mês m na ocupação o .
- $D = P \times M = \{d_{pm} \mid d_{pm} \in \mathbb{R}^+ \wedge p \in P \wedge m \in M\}$ é o conjunto com as distâncias máximas semanais que o profissional p percorreu durante o mês m .
- $I = P \times M = \{i_{pm} \mid i_{pm} \in \mathbb{R}^+ \wedge p \in P \wedge m \in M\}$ é o conjunto com as quantidades de vínculos privados que o profissional p teve no mês m .
- $U = P \times M = \{u_{pm} \mid u_{pm} \in \mathbb{R}^+ \wedge p \in P \wedge m \in M\}$ é o conjunto com as quantidades de vínculos públicos que o profissional p teve no mês m .

No contexto da modelagem proposta, o conceito de trilha de auditoragem se refere a um conjunto de regras destinadas a identificar alertas de fraude entre os servidores públicos da saúde. O conjunto de trilhas de auditoragem é denotado por $T = \{T_1, T_2, T_3, T_4, T_5\}$, enquanto $T_x = \{(p, \hat{M}_{xp}, a_{xp})\}$ representa um trio ordenado que contém: o profissional (p) que violou essas regras, os meses (\hat{M}_{xp}) em que essas violações ocorreram para esse profissional e o alerta (a_{xp}) indicado pela trilha x para o profissional p . Para os elementos deste trio ordenado, são aplicadas as seguintes restrições: (i) $p \in P$; (ii) $\hat{M}_{xp} \subset M$; (iii) $|\hat{M}_{xp}| > 0$; (iv) $\forall (m \in \hat{M}_{xp}) \rightarrow u_{pm} > 0$; (v) $a_{xp} \in \mathbb{R}^+$; (vi) $a_{xp} > 0$.

A Tabela 2 descreve as regras que \hat{M}_{xp} precisa atender para que um determinado profissional p seja enquadrado em cada uma das trilhas, bem como a fórmula para calcular o alerta (a_{xp}) de cada trilha. Tal alerta indica o quão distante o profissional está da norma estabelecida. Por exemplo, na trilha T_5 , são identificados servidores com uma carga horária semanal muito elevada. Assim, é utilizado um limite previamente estabelecido para essa carga horária, e quanto mais exceder esse limite, maior será a penalidade aplicada pelo alerta dessa trilha. Além disso, a penalização aumenta de acordo com o número de meses em que o servidor mantém essa carga horária elevada.

Tabela 2. Definição formal das regras de cada trilha de auditoragem.

#	Regras de \hat{M}_{xp}	Fórmula para calcular a_{xp}
T_1	$\hat{M}_{xp} = \{m \mid \forall m \rightarrow d_{pm} > \text{limiar_}D_m\}$	$a_{xp} = \sum_m^{ \hat{M}_{xp} } (d_{pm} - \text{limiar_}D_m)_{norm}$
T_2	$\hat{M}_{xp} = \{m \mid \forall m \rightarrow (\exists o \rightarrow (h_{pmo} > 60))\}$	$a_{xp} = \sum_m^{ \hat{M}_{xp} } \left[\sum_o^{ \mathcal{O} } (h_{pmo} - 60)_{norm} \right]$
T_3	$\hat{M}_{xp} = \{m \mid \forall m \rightarrow u_{pm} > 3\}$	$a_{xp} = \sum_m^{ \hat{M}_{xp} } (u_{pm} - 3)_{norm}$
T_4	$\hat{M}_{xp} = \{m \mid \forall m \rightarrow (u_{pm} + i_{pm}) > 10\}$	$a_{xp} = \sum_m^{ \hat{M}_{xp} } (u_{pm} + i_{pm} - 10)_{norm}$
T_5	$\hat{M}_{xp} = \left\{ m \mid \forall m \rightarrow \left(\sum_o^{ \mathcal{O} } h_{pmo} + f(d_{pm}) \right) > 126 \right\}$	$a_{xp} = \sum_m^{ \hat{M}_{xp} } \left[\left(\sum_o^{ \mathcal{O} } h_{pmo} + f(d_{pm}) \right) - 126 \right]_{norm}$

A função $f(d_{pm})$ na trilha T_5 calcula o tempo médio necessário para percorrer a distância d_{pm} entre as cidades. Além disso, na trilha T_1 , a variável $\text{limiar_}D_m$ representa um limite dinâmico derivado de uma abordagem estatística, usando a distância máxima semanal de todos os profissionais ao longo do período de tempo. Inicialmente, os dados foram agrupados por ano e, em seguida, calculou-se a amplitude interquartil (IQR) das distâncias em cada ano. Esse valor foi então multiplicado por um fator de escala de 1,5, conforme apresentado na Equação 1, onde Q_{3m} e Q_{1m} representam, respectivamente, o terceiro e o primeiro quartil das distâncias máximas semanais no ano do mês m .

$$\text{limiar_}D_m = Q_{3m} + 1,5(Q_{3m} - Q_{1m}) \quad (1)$$

Os limiares para as demais trilhas foram estabelecidos em colaboração com especialistas do MPMG. Na trilha T_2 , o objetivo é identificar situações em que o servidor tenha uma carga horária semanal superior a 60 horas para uma única ocupação. Já na trilha T_3 , busca-se identificar casos em que o servidor possua mais de três vínculos públicos no mesmo mês. Para a trilha T_4 , procura-se detectar situações em que o servidor possua mais de dez vínculos totais no mês. Por fim, na trilha T_5 , o objetivo é identificar casos em que a carga horária semanal total, somada a uma estimativa da distância percorrida entre as cidades, ultrapasse as 126 horas semanais. Esse valor de 126 horas equivale a uma carga horária de trabalho de 18 horas diárias, durante os sete dias da semana.

É importante ressaltar que todos os profissionais da base do CNES foram considerados na modelagem, mas as trilhas buscam encontrar alertas apenas para os servidores públicos. Isso parte do pressuposto de que mesmo que um profissional seja enquadrado em várias trilhas, caso ele possua apenas vínculos privados, ele não estaria gerando prejuízo ao patrimônio público. Nesse sentido, não é objetivo deste trabalho realizar auditoria interna em empresas privadas. Portanto, são considerados servidores públicos os profissionais que tenham pelo menos um vínculo público (i.e., $\forall(m \in \hat{M}_{xp}) \rightarrow u_{pm} > 0$).

Além da descrição das regras do \hat{M}_{xp} , na Tabela 2, é apresentado o cálculo do alerta a_{xp} de cada trilha. Tal cálculo consiste no somatório da diferença entre a variável

de interesse e o limiar, considerando cada mês em que o profissional descumpriu a regra da trilha. Antes de ser somada, a diferença é normalizada em uma escala de 1 a 100 (indicado pelo operador *norm*), para evitar que uma trilha domine as outras devido a diferentes ordens de grandeza das variáveis de interesse. Por exemplo, na trilha T_1 , a variável de interesse é a distância, medida em quilômetros, enquanto na T_3 é a quantidade de vínculos públicos, resultando em ordens de grandeza distintas.

4.4. Ranqueamento

Esta seção descreve a estratégia utilizada para ranquear os servidores da saúde suspeitos de fraude. Para cada servidor, é gerado um indicador de alerta a partir da combinação dos resultados individuais de cada trilha de auditoria ponderados por um grau pré-definido de risco. A Tabela 3 apresenta o grau de risco de cada trilha, estabelecido empiricamente em colaboração com auditores especialistas com base na gravidade dos alertas gerados por cada trilha de auditoria. Para o cálculo do indicador de alerta, cada trilha x recebe um peso numérico w_x de acordo com seu grau de risco, conforme a Equação 2.

$$w_x = \begin{cases} 1; & \text{se } x \in \{3\} \\ 0,1; & \text{se } x \in \{4,5\} \\ 0,01; & \text{se } x \in \{1,2\} \end{cases} \quad (2)$$

Tabela 3. Grau de risco de cada trilha.

Risco	Trilha
Alto	T_3 - Múltiplos vínculos públicos
Médio	T_4 - Número elevado de vínculos empregatícios T_5 - Carga horária de trabalho semanal elevada
Baixo	T_1 - Distância percorrida elevada T_2 - Expediente muito longo

Em suma, as trilhas classificadas como de alto risco recebem peso 1, as de médio risco têm peso 0,1, e as de baixo risco têm peso 0,01. Assim, é possível definir o indicador de alerta de fraude R_p de um profissional p como a soma dos produtos entre o alertas a_{xp} gerados por cada trilha x e o seu peso correspondente. Formalmente, esse indicador é expresso pela Equação 3.

$$R_p = \sum_{x=1}^5 (a_{xp} \times w_x) \quad (3)$$

Uma vez que o indicador de alerta R_p tenha sido calculado para cada profissional p , o ranqueamento é feito ordenando os profissionais a partir de seu indicador de alerta de forma decrescente. Dessa forma é gerado o conjunto \bar{P} que representa os profissionais ranqueados pelo indicador de alerta. $\bar{P} \subseteq P$ e $\bar{P} = \{p \mid \forall p \rightarrow R_p > R_{(p+1)}\}$.

5. Análise Experimental

Para avaliar a metodologia proposta, foi realizado um experimento considerando um conjunto específico de servidores públicos da saúde, conforme detalhado na Seção 5.1. Em seguida, na Seção 5.2, os resultados das trilhas propostas são caracterizados e analisados, a fim de aprofundar a compreensão sobre elas. Por fim, na Seção 5.3, a análise experimental é complementada ao examinar as características do processo de ranqueamento dos servidores com base nos indicadores de alerta de fraude.

5.1. Dados

Para a análise experimental, foi considerado um conjunto de dados referentes aos servidores da saúde do estado de Minas Gerais (MG). Os dados foram filtrados para incluir apenas os servidores da saúde com algum vínculo empregatício nos municípios desse estado. A coleta de dados foi realizada através do CNES, abrangendo o período de janeiro de 2015 a outubro de 2023. O conjunto final de dados contém um total de 838.443 servidores distribuídos nos 853 municípios de Minas Gerais.

5.2. Resultados das Trilhas

Nesta seção, são apresentados e analisados os resultados obtidos a partir das trilhas propostas no conjunto de dados considerado. A Tabela 4 apresenta a caracterização dos alertas gerados pelas trilhas, incluindo o grau de risco de cada uma, a quantidade total de servidores envolvidos, seus valores mínimo, máximo e médio, bem como a soma dos alertas de todos os servidores envolvidos. Os servidores são contabilizados a partir de seus respectivos números do Cartão Nacional de Saúde (CNS), que fornece uma identificação única de cada cidadão no Sistema Único de Saúde (SUS).

Tabela 4. Caracterização dos resultados das trilhas.

Trilha	Risco	#P	$\min(\mathbf{a}_{xp})$	$\max(\mathbf{a}_{xp})$	$\bar{\mathbf{a}}_{xp}$	$\sum \mathbf{a}_{xp}$
T_1	Baixo	9.710	1	6.205,75	323,37	3.139.994,97
T_2	Baixo	1.776	1	985,79	42,57	75.607,42
T_3	Alto	1.562	1	1.950	49,06	76.630
T_4	Médio	2.806	1	3.481	167,89	341.834
T_5	Médio	3.603	1	538,1	32,02	115.386,74

#P: Qtd. servidores $\min(\mathbf{a}_{xp})$: Alerta mínimo $\max(\mathbf{a}_{xp})$: Alerta máximo
 $\bar{\mathbf{a}}_{xp}$: Alerta médio $\sum \mathbf{a}_{xp}$: Soma dos alertas

Em relação à quantidade de servidores suspeitos apontados por cada trilha, observa-se que a trilha T_1 apresenta um número relativamente maior em comparação com as demais. Essa tendência é corroborada quando se considera a média dos alertas atribuídos, onde a trilha T_1 também se destaca por apresentar um valor significativamente mais alto do que as outras. Por exemplo, a média dos alertas da T_1 é pelo menos duas vezes maior do que a da maioria das trilhas. Tais valores sugerem uma concentração maior de alertas envolvendo a distância percorrida pelos servidores. Além disso, o alto número de casos identificados por T_1 também pode estar relacionado ao limiar utilizado nesta trilha, limiar_{D_m} , que é estabelecido de forma dinâmica por uma abordagem estatística (Equação 1), ao contrário das demais trilhas que possuem um limiar fixo.

Já sobre a trilha T_3 , classificada com o maior risco entre todas, destaca-se que, apesar de possuir uma quantidade menor de servidores suspeitos apontados em comparação com T_1 , T_4 e T_5 , a média dos alertas atribuídos ainda é significativa. Isso sugere que, embora o número absoluto de suspeitos seja menor, as irregularidades detectadas nessa trilha tendem a ser mais graves ou impactantes. Essa análise reforça a importância de considerar não apenas a quantidade, mas também a gravidade das irregularidades detectadas ao avaliar o risco associado a cada trilha de auditoria.

No geral, não é observado relação significativa entre o grau de risco da trilha e a média dos alertas. Por exemplo, as trilhas T_1 e T_2 , classificados com um risco baixo, apresentam médias de alertas muito diferentes entre si. Enquanto T_1 apresenta média de $\bar{a}_{1p} = 323,27$, a trilha T_2 possui $\bar{a}_{2p} = 42,57$, sendo este o segundo menor valor observado dentre todas as trilhas. Por outro lado, a trilha T_3 , classificada com um risco alto, possui uma média de alertas $\bar{a}_{3p} = 49,06$. Essa falta de associação entre o grau de risco e a média dos alertas sugere que outros fatores podem influenciar a magnitude das irregularidades detectadas em cada trilha.

Para aprofundar a análise da relação entre as trilhas para além do seu grau de risco, foi calculada a correlação entre os alertas gerados pelas trilhas para os servidores considerados. Nesta análise, foi utilizado o coeficiente de Pearson (r), que mede a correlação linear entre duas variáveis. Todos os coeficientes de correlação resultantes estão no intervalo $[-0,1; 0,2]$, indicando uma correlação fraca entre elas. Tal resultado sugere que a variação em uma variável não causa mudanças significativas nas outras, e cada trilha contribui com informações distintas para a análise.

5.3. Resultados do Ranqueamento

Nesta seção, são apresentados e analisados os resultados obtidos a partir do ranqueamento dos servidores proposto na Seção 4.4. Inicialmente, é apresentada uma análise qualitativa dos top 10 servidores classificados a partir da abordagem proposta. Em seguida, a influência de cada trilha no resultado da tarefa é analisada utilizando uma medida da qualidade de ranqueamento.

Análise Qualitativa. A Tabela 5 apresenta os top 10 servidores ranqueados de acordo com o indicador de alerta de fraude (R_p). Nela, as colunas representam os servidores ordenados, e as linhas apresentam os alertas a_{xp} gerados pelas trilhas T_x . A última linha apresenta o indicador de alerta de fraude do servidor.

Tabela 5. Top 10 servidores com maiores valores para o indicador de fraude R_s .

	#1	#2	#3	#4	#5	#6	#7	#8	#9	#10
a_{1p}	3.021,46	487,20	445,63	313,13	921,42	3.869,01	0	1.513,63	0	0
a_{2p}	0	0	0	0	0	0	0	0	0	0
a_{3p}	1.950,00	1.656,00	1.113,00	990,00	1.003,00	967,00	990,00	827,00	879,00	746,00
a_{4p}	874,66	692,66	379,66	762,33	441,00	120,00	84,00	735,00	91,66	92,00
a_{5p}	72,07	20,19	10,61	0	0	21,60	0	0	0	35,38
R_p	2.074,89	1.732,16	1.156,48	1.069,36	1.056,31	1.019,85	998,4	915,64	888,16	758,74

No geral, a análise do ranqueamento revela que os servidores que estão no topo do ranking possuem valores elevados de alertas a_{xp} para as trilhas T_1 (distância percor-

rida elevada), T_3 (múltiplos vínculos públicos) e T_4 (número elevado de vínculos empregatícios). Apesar do fato de a trilha T_1 possuir um grau de risco baixo e T_4 um grau médio, ainda assim esses servidores foram bem ranqueados por possuírem valores altos de alertas nessas trilhas combinados com alertas na trilha T_3 , que é de alto risco.

Os três primeiros servidores do top 10 exibem um padrão consistente de alertas. Todos eles possuem uma quantidade significativa de alertas na trilha T_3 , valores elevados de alerta para as trilhas T_1 e T_4 , além de alertas consideráveis na trilha T_5 (carga horária de trabalho semanal elevada). Além disso, nenhum dos servidores melhor ranqueados possui alertas para a trilha T_2 (expediente muito longo). Esses padrões sugerem a existência de comportamentos similares entre os servidores identificados, o que requer investigações mais detalhadas por parte dos auditores.

Influência das Trilhas. Para avaliar a influência de cada trilha nessa tarefa, é utilizado o método Discounted Cumulative Gain (DCG) [Wang et al. 2013], uma métrica de qualidade de ranqueamento. O DCG considera o somatório dos ganhos c_{px} ponderados pela posição de cada servidor no ranqueamento. Aqui, o ganho $c_{px} = a_{xp} \times w_x$ representa a influência da trilha x no indicador de risco do servidor p . A Equação 4 apresenta a fórmula para calcular o DCG, onde \bar{P} é o conjunto de servidores ranqueados e p é a posição do servidor no ranqueamento. Tal métrica permite uma avaliação mais precisa da contribuição de cada trilha para o indicador de risco global.

$$DCG_x = \sum_{p=1}^{|\bar{P}|} \frac{c_{px}}{\log_2(p+1)} \quad (4)$$

A Figura 3 apresenta os valores do DCG de cada trilha. Os resultados sugerem uma possível relação entre o valor do DCG e o risco associado a cada trilha. Por exemplo, a trilha T_3 , classificada como de alto risco, exibe um valor de DCG significativamente maior do que as trilhas com menor risco. Isso sugere que as trilhas com maior risco têm uma influência maior no processo de ranqueamento, contribuindo mais para a identificação dos servidores com potenciais irregularidades.

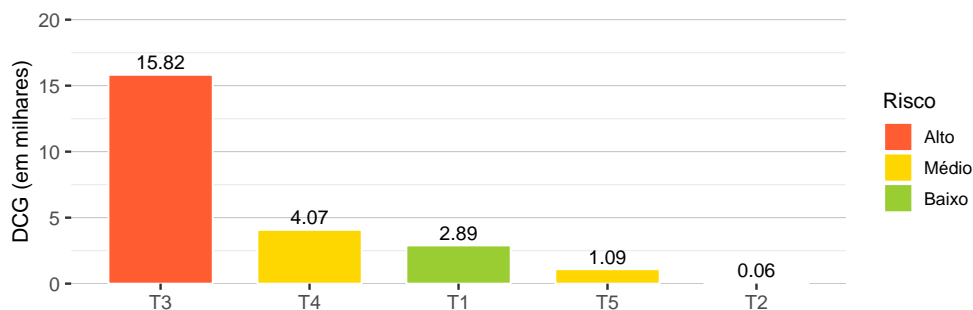


Figura 3. Influência de cada trilha no ranqueamento baseada no valor do DCG.

No entanto, nota-se uma exceção ao observar o resultado para a trilha T_1 . Apesar de ser classificada com um grau de risco baixo, ela possui um DCG maior que a trilha T_5 , que possui um grau de risco médio. Isso se deve ao fato de que a trilha T_1 gerou alertas para um número substancialmente maior de servidores em comparação com a T_5 .

(conforme Tabela 4). Portanto, mesmo tendo um grau de risco baixo, a T_1 foi uma trilha mais influente do que a T_5 no processo de ranqueamento devido ao seu maior impacto na identificação de potenciais irregularidades.

6. Conclusão

Este trabalho propôs uma abordagem baseada na modelagem de trilhas de auditoria para identificar e priorizar alertas de fraude relacionados a servidores públicos da saúde. Tais trilhas foram desenvolvidas como sequências de passos para detectar padrões suspeitos nos registros de atividades e deslocamentos dos servidores, permitindo uma análise eficiente e sistemática de potenciais casos de fraude. Além disso, elas foram definidas com base em dados do Cadastro Nacional de Estabelecimentos de Saúde (CNES), um sistema que reúne informações sobre profissionais e estabelecimentos de saúde no país.

Para validar a eficácia da metodologia proposta, foi realizado um experimento utilizando um extenso conjunto de dados de servidores públicos da saúde em Minas Gerais. Os resultados obtidos demonstram que as trilhas são capazes de elencar servidores com maior potencial de irregularidade, especialmente quando combinadas pelo método de ranqueamento. Tais resultados sugerem que a metodologia pode servir como uma ferramenta valiosa para os auditores, oferecendo uma primeira análise de triagem diante do grande volume de dados disponíveis. Portanto, a metodologia proposta não apenas oferece uma maneira automatizada de apontar potenciais fraudes entre os servidores da saúde, mas também ressalta a importância de uma abordagem integrada e multifacetada para a análise de dados de auditoria.

Limitações e Trabalhos Futuros. A principal limitação deste trabalho é a dependência dos dados disponíveis no CNES, o que pode influenciar a precisão e abrangência das análises realizadas. Além disso, questões éticas e legais relacionadas à privacidade dos servidores públicos também precisam ser consideradas. Como trabalho futuro, pretende-se explorar técnicas mais avançadas de análise de dados e a integração com outras fontes de dados para aprimorar ainda mais a detecção e prevenção de fraudes na área da saúde. Além disso, pretende-se executar uma etapa de validação manual dos resultados com especialistas para verificar a acurácia das trilhas propostas.

Agradecimentos. Ao Ministério Público do Estado de Minas Gerais (MPMG) pelo apoio através do Projeto Capacidades Analíticas. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e Amazon Web Services (AWS) pelo financiamento recebido através do projeto da parceria entre ambos. Por fim, à CAPES e FAPEMIG pelo apoio aos pesquisadores envolvidos.

Referências

- Brandão, M. A. et al. (2024). PLUS: A Semi-automated Pipeline for Fraud Detection in Public Bids. *Digit. Gov. Res. Pract.*, 5(1):5:1–5:16.
- Braz, C. S. et al. (2023). Análise de irregularidades em licitações públicas com foco em empresas de pequeno porte. In *WCGE*, pages 94–105. SBC.
- Costa, L. L. et al. (2023). Identificação de licitações suspeitas de fraude por meio de trilhas de auditoria. *iSys-Brazilian Journal of Information Systems*, 16(1):13–1.

- Domingues, M. et al. (2021). Programa Autoestima: Uma ferramenta Web pública e amigável que integra formação de profissionais da saúde e acolhimento psicossocial da população. In *WCGE*, pages 251–258. SBC.
- Handoko, B. L. and Rosita, A. (2022). The effect of skepticism, big data analytics to financial fraud detection moderated by forensic accounting. In *ICEEG*, pages 59–66.
- Kratcoski, P. C. (2018). *Fraud and Corruption in the Healthcare Sector in the United States*, pages 109–124. Springer International Publishing, Cham.
- Kumaraswamy, N. et al. (2024). Using a bayesian belief network to detect healthcare fraud. *Expert Syst. Appl.*, 238(Part F):122241.
- Mongwe, W. T. and Malan, K. M. (2020). The efficacy of financial ratios for fraud detection using self organising maps. In *SSCI*, pages 1100–1106. IEEE.
- Neubauer, T., Araujo, R., Fantinato, M., and Peres, S. (2022). Transparency promoted by process mining: an exploratory study in a public health product management process. In *WCGE*, pages 37–48. SBC.
- Oliveira, E. F. et al. (2021). O uso de tecnologias para detecção de fraudes na pandemia da covid-19. *Revista de Contabilidade e Controladoria*, 13(1):156–177.
- Oliveira, G. P. et al. (2022). Detecting inconsistencies in public bids: An automated and data-based approach. In *WebMedia*, pages 182–190. ACM.
- Oliveira, G. P. et al. (2023). Ranqueamento de licitações públicas a partir de alertas de fraude. In *BraSNAM*, pages 1–12. SBC.
- Pelissari, M. R. (2019). CNES como instrumento de gestão e sua importância no planejamento das ações em saúde. *Revista de Saúde Pública do Paraná*, 2(1):159–165.
- Pereira, A. K. d. S. et al. (2022). Usando redes complexas na identificação de empresas fraudulentas em licitações públicas. In *WCGE*, pages 13–24. SBC.
- Rocha, T. A. H. et al. (2018). Cadastro Nacional de Estabelecimentos de Saúde: evidências sobre a confiabilidade dos dados. *Ciência & Saúde Coletiva*, 23(1):229–240.
- Silva, C. A., dos Santos, E. A., de Oliveira Ribeiro, F., and da Rosa, F. S. (2020). Consciência, Prevenção e Detecção contra Fraude: Estudo com Auditores Internos e Contadores do Setor Público Brasileiro. In *USP International Conference on Accounting*.
- Silva, M. O. et al. (2023). Análise de sobrepreço em itens de licitações públicas. In *WCGE*, pages 118–129. SBC.
- Wang, Y. et al. (2013). A theoretical analysis of NDCG type ranking measures. In *COLT*, volume 30 of *JMLR Workshop and Conference Proceedings*, pages 25–54. JMLR.org.