

BDI-Based Multi-Agent System for Identifying Fraud Patterns in Bidding Processes

Mariana Mazzo Heitor¹, Jerusa Marchi¹

¹Departamento de Informática e Estatística
Laboratório de Inteligência Artificial e Algoritmos – LIAA
Universidade Federal de Santa Catarina
Florianópolis – SC – Brasil

mariana.mazzo.heitor@grad.ufsc.br, jerusa.marchi@ufsc.br

Abstract. *Brazilian public agencies must open bidding processes for works, services, or purchases to ensure fair competition, yet these procedures are vulnerable to fraud and demand investigation by prosecutors. Manual verification is complex due to large data volumes. To address this, this work proposes a Multi-Agent System (MAS) that automates fraud detection by simulating prosecutors' behavior. Intelligent agents perceive bidding document data and exchange information. Agents are organized into groups by hyper-typology, representing sets of checks for fraud evidence within major irregularity categories. Each group searches for signs of fraud in its assigned hyper-typology and issues alerts if detected. Validated through a case study with fictitious data, the system achieved satisfactory results despite limitations, proving to be a viable and promising alternative for automating fraud investigation in bidding procedures.*

Resumo. *Órgãos públicos brasileiros devem abrir licitações para obras, serviços ou compras visando competição justa, mas esses processos são vulneráveis a fraudes e exigem investigação por procuradores. A verificação manual é complexa pelo grande volume de dados. Para facilitar esse processo, este trabalho apresenta um Sistema Multiagente (SMA) que automatiza a detecção de fraudes ao simular o comportamento de procuradores. Agentes inteligentes varrem dados dos documentos de licitação e trocam informações. Os agentes são organizados em grupos por hipertipologias, conjuntos de verificações de indícios de fraude dentro de categorias de irregularidade baseadas nos principais tipos de fraude. Cada grupo busca sinais em sua hipertipologia e emite alerta quando adequado. Validado com estudo de caso usando dados fictícios, o sistema obteve resultados promissores apesar das limitações, mostrando-se alternativa viável para automatizar a investigação de fraudes em licitações.*

1. Introdução

Licitação é o processo administrativo realizado pela Administração Pública com o objetivo de, baseado em condições estabelecidas previamente em um edital, selecionar a proposta mais vantajosa para a contratação e aquisição de bens e serviços, enquanto garante o caráter competitivo, preserva igualdade de condições entre os licitantes e promove o interesse público de forma eficiente [TCU 2024, da Silva and de Oliveira 2024]. Tais processos estão sujeitos a fraudes [Rodrigues and Filho 2017]. Segundo o *OECD*

Foreign Bribery Report [OECD 2016], as compras públicas são uma das atividades governamentais mais vulneráveis à corrupção, sendo que mais da metade dos casos ocorre em licitações e quase dois terços, ocorre em setores profundamente associados a elas.

Nesse contexto, tem-se a *fraude licitatória* como uma vertente da corrupção que compromete a transparência, a eficiência e a economia dos recursos públicos por meio de acordos entre licitantes e agentes ou manipulação de editais para beneficiar empresas [TB 2024],[da Silva and de Oliveira 2024]. Isso impacta negativamente a integridade da aplicação dos recursos, gerando prejuízos econômicos e sociais, além de intensificar a desconfiança institucional e reduzir a qualidade dos serviços públicos. Para mitigar o problema, a Lei nº 14.133/2021 prevê sanções severas e medidas preventivas, como exigência de transparência em todas as etapas do processo licitatório [da Silva and de Oliveira 2024]. Contudo, ainda que os principais tipos de fraude e suas características sejam conhecidas, a análise para identificá-la é complexa devido ao grande volume de dados extraídos de editais, documentos e participantes. O tratamento desses dados exige trabalho técnico e especializado, a busca manual é demorada e propensa a falhas na identificação de detalhes específicos que indicam fraude [Wüst et al. 2024]. Além disso, a investigação demanda um tempo significativo do promotor na validação de denúncias o que é agravado em casos falso-positivos ou mediante verificações repetidas.

Assim, torna-se promissora a implementação de um Sistema Multiagente (SMA) para apoiar a detecção de indícios de fraude em licitações. Diferente de abordagens estáticas, o SMA permite agregar conhecimento de especialistas diretamente nos agentes, que passam a raciocinar sobre os dados e tomar decisões com maior precisão. Na prática, o sistema recria o cenário de investigação: agentes assumem o papel de promotores, navegam pelo ambiente da licitação, interpretam documentos, avaliam participantes e compartilham descobertas entre si para identificar sinais de fraude de forma colaborativa. Vale ressaltar, entretanto, que a arquitetura proposta atua como um suporte à tomada de decisão, não substituindo o papel do promotor, o qual será responsável pela interpretação contextual e pela decisão final a respeito das evidências apontadas pelo sistema.

Este trabalho foca no uso de agentes para analisar indicadores de fraude em *trilhas de investigação* que combinam diversas verificações. Juntos, avaliam se houve direcionamento de licitação e definem a gravidade com base nas evidências encontradas. O artigo está organizado da seguinte forma: a Seção 2 apresenta os trabalhos relacionados. A Seção 3 apresenta brevemente o projeto no qual este trabalho se insere. Na Seção 4, a metodologia adotada para lidar com o problema da identificação de indicativos de fraude por meio da implementação do SMA é apresentada e, na sequência, a arquitetura - Seção 5, e a dinâmica do SMA - Seção 6. Os resultados preliminares são apresentados na Seção 7. Por fim, a Seção 8 traz a conclusão perspectivas para trabalhos futuros.

2. Trabalhos Relacionados

Para fundamentar a base teórica e prática deste estudo, foi realizada uma revisão sistemática em repositórios como Google Scholar e DBLP, com foco em Sistemas Multiagentes e Fraudes em Licitações ou Fraudes Montetárias. Dois trabalhos principais foram encontrados e são brevemente apresentados nesta Seção.

Em [Ralha and Silva 2012], a detecção de cartéis em compras públicas é considerada um problema complexo devido ao enorme volume de dados e às diversas es-

estratégias usadas para ocultar fraudes. Para enfrentar esse desafio, os autores desenvolveram o AGMI, uma ferramenta de agent-mining que integra mineração de dados distribuída, descoberta de conhecimento em bases de dados e Sistemas Multiagentes, projetada para apoiar a detecção, prevenção e monitoramento de cartéis em licitações públicas. Seu diferencial está em adicionar um agente inteligente ao processo tradicional de mineração, permitindo incorporar conhecimento de especialistas e heurísticas, e com essa abordagem híbrida o AGMI supera limitações da mineração clássica e torna mais eficaz a identificação de cartelização em compras públicas.

Já [Alexandre and Balsa 2018], aborda a ineficiência de investigações semi-automatizadas que usam regras fixas para identificar lavagem de dinheiro. O número crescente de transações e novas regulamentações tornam esses sistemas menos eficazes. Os autores propuseram um Sistema Multiagente para analisar e sinalizar transações suspeitas, auxiliando analistas humanos. Primeiro, constroem perfis de comportamento do cliente usando mineração de dados para revisar o histórico de operações. Esses dados são usados como base de conhecimento para um Sistema Multiagente construído na plataforma JaCaMo [Hübner et al. 2020]. O sistema possui agentes especializados em encontrar atividades suspeitas e agentes que auxiliam analistas humanos, aprendendo com suas decisões. Essa abordagem mostrou-se melhor na identificação de comportamentos irregulares complexos, encontrando inclusive casos de lavagem de dinheiro não detectados por sistemas tradicionais baseados em regras.

3. Contexto do Trabalho: Projeto CÉOS

O projeto CÉOS ¹ é uma pesquisa em parceria entre o Departamento de Informática e Estatística (INE) da Universidade Federal de Santa Catarina (UFSC) e o Ministério Público de Santa Catarina (MPSC) com objetivo de automatizar a análise e extração de conhecimento de grandes volumes de dados. Por meio de coleta, integração, organização e processamento, busca auxiliar e aprimorar a tomada de decisões em domínios complexos do setor público, contribuindo para prevenção e combate à corrupção.

Com o crescimento do volume de dados, extrair informações de editais e documentos tornou-se uma tarefa complexa e demorada, exigindo tecnologias para gerenciamento e análise. A partir dessa demanda surgiu o projeto CÉOS, visando tratar e manipular os dados para gerar informação útil e relevante aos promotores, otimizando a inspeção e a análise de licitações e indicadores de possíveis fraudes.

Este trabalho apresenta o Sistema Multiagente, que, integrado a um painel inteligente [Pierotti et al. 2024] auxilia na varredura, identificação e coleta de achados em processos de licitação, com objetivo de verificar, de forma inteligente e autônoma, indicadores de fraude, promovendo agilidade e acurácia às investigações.

4. Metodologia

O sistema desenvolvido utiliza agentes para imitar o raciocínio de promotores conduzindo uma investigação. As investigações seguem trilhas de investigação chamadas *hipertipologias*, que representam categorias de fraude. Conjuntos de hipertipologias são agrupados em Categorias e são compostos por conjuntos de *tipologias*, conforme Tabela 1, que detalha a Categoria “Análise da relação entre empresas licitantes”. Essas tipologias e seus

¹ link para a página do projeto: <https://ceos.ufsc.br/>

respectivos parâmetros para identificar fraude foram definidas com base em conhecimento de domínio fornecido, em reuniões técnicas, por especialistas do Ministério Público.

Tabela 1. Hipertipologias analisadas para a Categoria “Análise da relação entre empresas licitantes”. Fonte: MPSC

I. Análise da relação entre empresas licitantes	Hipertipologia A	Empresas participantes de uma mesma licitação compartilham características	01	Empresa licitante com sócio em comum com outra empresa licitante
			02	Empresa licitantes com ex-sócio em comum com outra empresa licitante
			03	Familiares consanguíneos de primeiro grau em comum entre sócios de empresas licitantes
			04	Sócio de uma empresa licitante é empregado de outra empresa licitante
			05	Empresas licitantes com contador em comum
			06	Empresas licitantes estão sediadas no mesmo endereço
			07	Empresas licitantes possuem mesmo telefone, e-mail ou grupo econômico
	Hipertipologia B	Empresas participantes de uma mesma licitação combinam de uma sempre perder (perdedora contumaz) para outra ganhar, ou alternam vitórias	08	Empresa licitante é perdedora contumaz
			09	Empresa licitante é vencedora contra empresa perdedora contumaz
			10	Alternância de vitórias entre empresas licitantes
	Hipertipologia C	Empresas participantes de uma mesma licitação apresentam propostas com proporcionalidade de valor/preço	11	Empresa apresenta propostas simétricas acima de patamar definido
	Hipertipologia D	Propostas idênticas entre Licitantes em Unidades Gestoras Diferentes	12	Empresa apresenta propostas idênticas acima de patamar definido
	Hipertipologia E	Conluio já identificado	13	Empresas que já tiveram conluio comprovado

Para verificar cada tipologia, o sistema emprega diversos agentes organizados de forma coordenada e cooperativa. Com base nos indicativos de fraude encontrados, o sistema estabelece a gravidade da fraude e exibe ao usuário por meio de um alerta. Nesta Categoria, são analisadas as hipertipologias A, B, C, D e E, definidas na Tabela 1.

Nesse contexto, pode-se definir *tipologia*, em termos computacionais, como uma regra de inferência para identificar indícios de fraude. O conceito de *hipertipologia*, então, é modelado estruturalmente como um conjunto de tipologias correlacionadas.

A implementação utiliza a Plataforma JaCaMo [Hübner et al. 2020], que integra a linguagem Jason aos frameworks CArtaGO e Moise. O SMA é estruturado em três dimensões propostas pela plataforma: agentes, ambiente e organização, detalhadas na Seção a seguir. Ademais, os agentes adotam modelo BDI (Belief-Desire-Intention), o qual permite que o comportamento do sistema seja explicado em termos de crenças, desejos e intenções. Nesse contexto, a arquitetura fundamenta-se no conceito de raciocínio prático, o qual consiste no processo de decidir quais objetivos deseja-se alcançar e quais ações executar para atingi-los, determinando o plano de ação do agente [Hübner et al. 2007].

5. Arquitetura do Sistema Multiagente

O sistema proposto organiza os agentes através de esquemas e papéis. A organização do sistema multiagente é composta por: um agente gerente, responsável por gerenciar os outros agentes, criando grupos para as hipertipologias e definindo papéis aos agentes responsáveis por coordenar um respectivo grupo, e por buscar na base de dados os editais de licitação, selecionando-os e repassando-os aos agentes de hipertipologia; cinco agentes hipertipologia, responsável por criar grupo para a hipertipologia, definindo papéis aos agentes responsáveis por realizar a análise das tipologias, por repassar os editais aos agentes de tipologia, os quais são enviados de forma sequencial, até a finalização da análise do

que está sendo investigado, e por criar o alerta da respectiva hipertipologia ao receber o resultado dos agentes de tipologia, definindo o seu nível de gravidade - o maior valor entre as tipologias detectadas ou o nível de gravidade da hipertipologia, caso todas tenham sido identificadas - e gerando uma descrição a respeito das tipologias identificadas - a partir dos dados das tipologias e dos dados salvos no documento JSON - para notificar as principais informações da fraude identificada ao usuário; e treze agentes tipologia, responsável por realizar consultas na base de dados, verificando se há algum indicativo de fraude no edital licitatório que está sendo investigado e, em caso positivo, armazenando informações relevantes a respeito da irregularidade e da empresa/licitação em um documento JSON, e retornar ao seu respectivo agente de hipertipologia o resultado da análise, sendo representado como uma lista com *false* em caso de regularidade e com informações - número da tipologia, nome da tipologia e gravidade da tipologia - em caso de irregularidade.

Esses agentes são divididos em dois tipos de grupos distintos. O primeiro, chamado *groupHipertipologia*, contém o agente gerente e todos os agentes hipertipologia. O segundo, chamado *groupHipertipologiaN* - onde N representa os valores A, B, C, D e E, dependendo da hipertipologia abordada no grupo -, contém o agente hipertipologia correspondente ao grupo e seus respectivos agentes tipologia. A Figura 1 apresenta uma representação da arquitetura descrita em relação aos grupos *groupHipertipologia* e *groupHipertipologiaB* - considerando que os outros *groupHipertipologiaN* possuem estrutura semelhante - e aos artefatos que estão observando.




Figura 1. Modelagem da arquitetura dos grupos da organização.

O grupo *groupHipertipologia* possui o *schemeHipertipologia*, que é separado em duas *missions* diferentes. A primeira consiste na criação e gerenciamento dos grupos de cada hipertipologia. A última consiste na busca pelos editais licitatórios na base de dados e seu posterior repasse aos agentes *hipertipologia*, sendo uma obrigação do agente *gerente*. O funcionamento geral do grupo pode ser observado na Figura 2.

Em relação ao grupo *groupHipertipologiaN*, há um *scheme* por hipertipologia, sendo denominados como *schemeHipertipologiaN*. Eles funcionam de forma semelhante, sendo separados em uma *mission* por tipologia presente na hipertipologia. Cada *mission*, então, consiste em realizar a busca na base de dados a respeito da tipologia investigada, retornando o resultado da análise do indicativo de fraude. Essas *missions* são atribuídas, de




Figura 2. Modelagem da funcionalidade do grupo *groupHipertipologia*.

forma obrigatória, aos agentes *tipologia*, sendo determinadas a partir do *role* da tipologia correspondente. A Figura 3 apresenta o funcionamento geral do grupo *groupHipertipologiaB* (para os demais grupos, as ações são semelhantes).




Figura 3. Modelagem da funcionalidade do grupo *groupHipertipologiaB*.

6. Dinâmica do Sistema Multiagente

O sistema multiagente inicia quando o agente *gerente* executa o *plan start*, criando a organização e seu artefato correspondente, ao qual se junta em seguida. Depois, o *gerente* cria o grupo *groupHipertipologia* e o artefato que será observado pelos membros desse grupo. Com o grupo criado, ele envia um *achieve* para cada agente listado em *membrosHipertipologia* — sua base de crenças com os participantes do grupo — para que se unam à organização e adotem um *role* nela. Por fim, ao receber a confirmação de que o grupo foi completamente formado, o *gerente* cria o *scheme* do grupo.

Ao finalizar esse conjunto de ações, o agente *gerente* executa a *mission mission-BuscaEdital*, que busca na base de dados os editais de licitação a serem analisados. Isso é feito por uma consulta SQL ao banco, cujo resultado é armazenado como um array de string na propriedade observável *resultEdital* do artefato. Essa propriedade, inicializada com o valor *false*, passa a conter `[id_proc_licit1, id_proc_licit2, ..., id_proc_licitN]`, em que *N* é a quantidade de editais encontrados na base de dados.

O agente *gerente*, ao observar uma mudança na propriedade *resultEdital*, busca a lista de membros do *groupHipertipologia* e envia a todos o array de editais licitatórios selecionados por meio de um *achieve*, para que executem o *plan sendEdital*. Seu funcionamento pode ser observado no fluxo de interação apresentado na Figura 4.




Figura 4. Interação dos agentes em *resultEdital* do agente *gerente*.

Os agentes *hipertipologia*, por outro lado, inicializam e aguardam que o agente *gerente* informe para se unirem à organização e comecem a focar nos artefatos da organização e do grupo ao qual pertencem, adotando em sequência o papel correspondente à letra da hipertipologia a que pertencem.

Ao entrarem no grupo, esses agentes executam a *mission missionHipertipologia*, que funciona de forma semelhante ao *goal start* do agente *gerente*: cria um *workspace* para o grupo específico da respectiva tipologia, além dos grupos, artefatos e *schemes* correspondentes. Diferente do *gerente*, não usa uma lista de membros na base de crenças; em vez disso, define os agentes membros concatenando *tipologiaX* — sendo X a letra da *hipertipologia* do agente — com um valor N, variando de 1 até a quantidade de tipologias presentes naquela hipertipologia.

Em seguida, ao receber um *achieve* do agente *gerente*, eles executam o *plan sendEdital*, que seleciona o primeiro edital do array e o envia para as tipologias pelas quais são responsáveis. Após o envio, os agentes *hipertipologia* atualizam a crença *editaAtual* com o número do edital enviado e a *editaRestante* com o restante do array de editais. A definição do *plan sendEdital* pode ser observada no fluxo de interação da Figura 5.

Os agentes *hipertipologia*, então, passam a aguardar o resultado da análise dos agentes *tipologia* pelos quais são responsáveis. Isso é feito a partir do valor de *hipertipologia* em sua base de crenças, definida inicialmente como *hipertipologia([null,null,...,null])*, sendo um array com N posições — N representando a quantidade de tipologias que cada hipertipologia possui — todas definidas como *null*.

Quando houver alteração no valor da crença *hipertipologia*, os agentes *hipertipologia* reagem executando uma sequência de ações ao receber os resultados de análise das tipologias — valores do array diferentes de *null*. O próximo passo é realizar verificações para definir o caminho a seguir. A primeira é se houve indicativo de fraude, analisando as informações recebidas dos agentes *tipologia* para verificar se o primeiro valor da lista de todas as informações recebidas é *false*, o que indica que nenhuma fraude foi detectada. Nesse caso, os agentes *hipertipologia* não criam alerta, apenas retornam a crença *hipertipologia* ao valor inicial e enviam o próximo processo licitatório a ser analisado.




Figura 5. Interação dos agentes em *sendEdital* do agente *hipertipologiaB*.

A segunda situação ocorre quando há indicativo de fraude em apenas parte da hipertipologia — parte das tipologias detectaram indícios, enquanto outras estão regulares. Para checar isso, de forma semelhante à situação anterior, verifica-se o primeiro valor da lista de informações recebida, analisando se algum é igual a *false*, o que indica que pelo menos um agente *tipologia* não detectou fraude. Nesse caso, um alerta é criado. Antes disso, é preciso definir o nível de gravidade: os agentes *hipertipologia* identificam qual tipologia possui o maior valor e usam esse resultado para definir a gravidade do alerta.

Ao obter esse valor, eles buscam qual é o edital que está sendo analisado e as informações a respeito da hipertipologia para construir o alerta, que consiste em, inicialmente, verificar os resultados de fraude que foram passados aos agentes *hipertipologia*, buscando o documento JSON com as informações da fraude caso o resultado não seja *false*. Ao identificar o documento, o conteúdo é lido e convertido em um JSONArray, que é usado para a construção da descrição longa do alerta. Essa descrição é gerada a partir de um template, que possui uma formatação pré-definida de acordo com a hipertipologia e com a tipologia, utilizando as informações obtidas do JSON para completar as frases geradas. Em seguida, é executado um SQL para adicionar o alerta e sua respectiva categoria - caso não tenha sido previamente armazenada - no banco de dados. Por fim, a crença *hipertipologia* é redefinida para seu valor inicial e um novo processo licitatório é enviado para ser analisado. A Figura 6 mostra o fluxo de funcionamento da geração de alertas.

A última situação se trata de quando foi detectado indicativo de fraude para todas as tipologias presentes na hipertipologia, sendo caracterizada como uma “fraude completa”. Ela irá funcionar de forma semelhante a anterior, buscando as informações da hipertipologia e, a partir dela, criando um alerta. Entretanto, ao invés de calcular o valor da gravidade, utiliza-se o nível padrão da hipertipologia, definido em *info_hipertipologia*.

Os agentes *tipologia*, por fim, inicializam e aguardam o agente *hipertipologia* correspondente chamá-los a unirem-se à organização e focarem nos respectivos artefatos da organização e do grupo. Para definir o *role* que o agente assumirá no grupo, será verificado se um determinado *role* do grupo ao qual pertence já foi adotado por outro agente, contando quantos agentes assumiram esse *role* e somente adotá-lo caso nenhum




Figura 6. Fluxo de geração de alertas do artefato *ArtefatoHipertipologia*.

outro agente o tenha assumido. Ao definir um *role*, além de adotá-lo, o agente armazena o nome do respectivo *role* e as informações da tipologia correspondente, no formato *info_tipologia(NumeroTipologia, NomeTipologia, GravidadeTipologia)*, na base de crença.

Esses agentes, ao entrarem no grupo, executam a *mission missionTipologiaN* - sendo N o valor numérico que representa o número da tipologia pela qual o agente é responsável -, que realiza a consulta da tipologia para o edital licitatório que está sendo investigado. Para isso, os agentes, inicialmente, buscam as informações a respeito da tipologia - obtidas a partir da crença *info_tipologia* - e esperam o agente *hipertipologia* responsável repassar o edital que será verificado.

Ao receber o edital, os agentes realizam uma consulta SQL no banco de dados, armazenando o resultado em uma propriedade observável *resultTipologiaN* como um array de arrays de tuplas, em que cada array dentro do “array principal” equivale a um resultado da consulta e os elementos desses arrays exibem as informações obtidas a partir da consulta, sendo armazenados no formato *nomeAtributo(valorAtributo)*. Além disso, a função é responsável por, caso tenha pelo menos um valor de retorno, salvar os dados em um arquivo JSON. Por fim, os agente indicam que o edital terminou de ser analisado, removendo *num_edital* de sua base de crenças e esperando pelo próximo edital.

Ao mesmo tempo, os agentes reagem quando observam uma mudança de valor na propriedade observável *resultTipologiaN*, verificando se o retorno é uma lista vazia, o que indica que não foi identificado nenhum indicativo de fraude. Em caso afirmativo, é enviado ao agente *hipertipologia* responsável um *achieve saveResultTipologiaN* - *plan* responsável por guardar o resultado da investigação - com o valor `[false]`. Em caso negativo, são buscadas as informações a respeito da tipologia, sendo enviado ao agente *hipertipologia* responsável um *achieve saveResultTipologiaN* com os dados da tipologia no formato `[NumeroTipologia, NomeTipologia, GravidadeTipologia]`, indicando que foi detectado indicativo de fraude. A Figura 7 apresenta o fluxo de retorno do resultado da consulta para a tipologia 8.




Figura 7. Interação dos agentes no retorno de resultado do agente *tipologia8*.

7. Resultados

Devido à confidencialidade dos dados reais, foi elaborado um estudo de caso com dados fictícios para demonstrar o funcionamento do sistema. As tabelas foram projetadas em PostgreSQL com arquitetura similar à original. Para validação, a base foi populada com quinze processos licitatórios, sessenta e nove itens, cinquenta e duas participações, duzentas e sessenta e uma cotações, vinte estabelecimentos e sessenta e seis sócios. Cenários fraudulentos foram inseridos intencionalmente para validar as consultas SQL de detecção de irregularidades. De forma análoga, foram incluídos registros sem anomalias, com o intuito de avaliar a robustez do sistema em relação a erros e falsos positivos.

Das 15 licitações analisadas, 10 apresentam indícios listadas a seguir no formato $\langle \text{Licitação}_i \rangle \{ \langle \text{lista de tipologias} \rangle \}$ como segue: $L_1 \{6, 8, 9\}$, $L_3 \{1, 6, 7, 8, 9\}$, $L_4 \{1, 6\}$, $L_7 \{6, 7\}$, $L_8 \{1, 10\}$, $L_9 \{11\}$, $L_{10} \{8, 9\}$, $L_{12} \{1, 11\}$, $L_{13} \{1, 10\}$ e $L_{14} \{1, 10\}$. As licitações L_2 , L_5 , L_6 , L_{11} e L_{15} não apresentaram fraude.

Vale ressaltar que, embora o SMA tenha sido projetado para suportar todas as hipertipologias e tipologias dentro do escopo definido, não foi possível obter todos os dados necessários para a análise. Devido a isso, algumas tipologias - L_2 , L_3 , L_4 , L_5 e L_{13} - não puderam ser analisadas, retornando o resultado como se nenhuma fraude tivesse

sido encontrada e adicionando um log “Dados insuficientes”. A Tabela 2 apresenta as tipologias identificadas pelo sistema para cada licitação.

Tabela 2. Tipologias identificadas por licitação.

Licitação	Tipologias identificadas	Licitação	Tipologias identificadas
L_1	Sem fraude	L_9	{8, 9, 10, 11}
L_2	Sem fraude	L_{10}	Sem fraude
L_3	{1, 6, 7}	L_{11}	Sem fraude
L_4	{1, 8, 9, 10, 11}	L_{12}	{1, 11}
L_5	Sem fraude	L_{13}	{1, 8, 9, 10}
L_6	Sem fraude	L_{14}	{1, 10}
L_7	{6, 7, 10}	L_{15}	Sem fraude
L_8	{1, 10}		

Os resultados evidenciaram três limitações principais na detecção de fraudes. A primeira é a dificuldade com dados em formatos diferentes. Na tipologia 6, que analisa empresas no mesmo endereço, variações como “Doutor” e “Dr.” são tratadas como dados distintos. Isso impede a identificação do indício. A segunda ocorre na tipologia 11, que verifica propostas com diferença inferior a 3%. Surgiram falsos positivos devido a natureza competitiva da disputa, sendo necessário incrementar análises nesta “trilha de investigação” antes de gerar o alerta. Por fim, houve falha nas tipologias 8, 9 e 10. O erro decorre do SQL que considera apenas dados do processo licitatório atual, ignorando o histórico completo de vitórias e derrotas da empresa. Um ajuste neste SQL se faz necessário para incluir esse histórico, ajustando a verificação e gerando os alertas esperados.

Analisando o desempenho do sistema, a Tabela 3 sintetiza as métricas estatísticas, demonstrando sua capacidade preditiva na identificação de padrões fraudulentos. Conforme apresentado na tabela, o sistema alcançou, para a classe “Fraude”, um recall de 57,14%, uma taxa de precisão de 54,55%, um F1-score de 55,81% e uma taxa de falsos positivos de 11,90%.

Tabela 3. Métricas estatísticas de desempenho do SMA.

Classe	Precisão	Recall	FNR	F1-Score	TNR	FPR
Fraude	0,5455	0,5714	0,4286	0,5581	0,8810	0,1190
Sem Fraude	0,8916	0,8810	0,1190	0,8862	0,5714	0,4286

8. Conclusão e Trabalhos Futuros

Este trabalho avaliou a viabilidade de um Sistema Multiagente (SMA) na detecção de indicativos de fraudes em licitações. O objetivo foi desenvolver uma versão inicial de SMA capaz de consultar uma base de dados, identificar indícios de fraude com base nas hiper-tipologias investigadas e gerar alertas informativos ao usuário. Para isso, utilizou-se a plataforma JaCaMo na implementação, focando na definição e orquestração da dimensão organizacional do SMA. O sistema consulta o banco de dados e retorna o resultado da análise ao agente responsável, que gerencia os dados e cria os alertas correspondentes. Seu uso justifica-se pela modularidade e separação de contexto, permitindo que cada agente seja responsável por um escopo específico, e pela escalabilidade, facilitando a incorporação de novas tipologias e de responsabilidades mais complexas aos agentes.

Os resultados demonstram que a abordagem multiagente é viável e promissora para automatizar a investigação de fraudes em processos licitatórios. O SMA mostrou-se uma ferramenta relevante no combate a fraudes, auxiliando na identificação de indícios de fraude e atuando de forma adequada segundo as funcionalidades implementadas, cumprindo seu papel de análise e geração de alertas com base nas regras e dados disponíveis. O funcionamento foi validado no estudo de caso, que comprovou o desempenho do sistema. Os resultados também indicaram pontos de melhora no sistema, como o tratamento de dados em formatos distintos e a redução de falsos positivos, através da implementação de novos cruzamentos de dados e da ampliação da base de informações. Pretende-se ainda integrar agentes que possam buscar, de forma autônoma, informações externas em bases públicas e buscadores, aumentando o poder de investigação da ferramenta. Além disso, planeja-se que os agentes sejam capazes de sintetizar os achados em um documento acessível aos promotores para auxiliá-los a tomar decisões de forma mais precisa.

Referências

- Alexandre, C. and Balsa, J. (2018). A multi-agent system based approach to fight financial fraud: An application to money laundering. *Preprints*.
- da Silva, J. V. S. and de Oliveira, R. D. (2024). Fraude em licitações: uma perspectiva da lei nº 14.133/2021. *Revista Científica COGNITIONIS*.
- Hübner, J. F., Boissier, O., Bordini, R. H., and Ricci, A. (2020). *Multi-Agent Oriented Programming: Programming Multi-Agent Systems Using Jacamo*. MIT Press.
- Hübner, J. F., Bordini, R. H., and Wooldridge, M. (2007). *Programming Multi-Agent Systems in Agentspeak Using Jason*. Wiley-Interscience.
- OECD (2016). *Preventing Corruption in Public Procurement*. Organisation for Economic Cooperation and Development.
- Pierotti, F., Jochem, J. E. M., Steffen, M. A., Soares, D., Benvenuti, M., Pereira, B. S., Bornia, L. G., dos Santos, M. M., Geronimo, G. A., Zibetti, A., Dorneles, C., Carvalho, J. T., Marchi, J., Castro, M., Fileto, R., Werner, S., and Mello, R. (2024). Desenvolvimento de um painel integrado inteligente para auxílio na identificação de fraudes em processos de compras públicas. In *Anais Estendidos do XXXIX Simpósio Brasileiro de Bancos de Dados*, pages 295–301, Porto Alegre, RS, Brasil. SBC.
- Ralha, C. G. and Silva, C. V. S. (2012). A multi-agent data mining system for cartel detection in brazilian government procurement. *Expert Systems with Applications*.
- Rodrigues, N. C. S. and Filho, R. N. L. (2017). Modalidades licitatórias e o risco de ocorrência de fraudes nos municípios baianos fiscalizados pela controladoria geral da união. *CCCCSS Contribuciones a Las Ciencias Sociales*.
- TB (2024). *Métodos de Detecção de Fraude e Corrupção em Contratações Públicas*. Transparência Brasil.
- TCU (2024). *Licitações & Contratos - Orientações e Jurisprudência do TCU*. Tribunal de Contas da União.
- Wüst, A., Dorneles, C. F., Tyska, J., Marchi, J., Castro, M., Fileto, R., Mello, R., and Werner, S. S. (2024). Céos: Inteligência de dados para a sociedade. Technical report, Universidade Federal de Santa Catarina, Florianópolis.