

TJGO: USO DE IA PARA SELEÇÃO DE OBJETOS DE AUDITORIA

Samuel Sabino Caetano, Marcos Nunes Laureano

Servidor do Tribunal de Justiça do Estado de Goiás. Mestre em Ciência da Computação pela Universidade Federal de Goiás. Certificado ITIL, COBIT, ISO 20000 e 27001. Atualmente, atua como auditor interno e dirigente de cooperativa de crédito. Marcos Nunes Laureano, servidor do Tribunal de Justiça do Estado de Goiás, (TJGO) desde 2003. Graduado em Direito pelo Centro de Ensino Superior de Catalão/GO, pós-graduado em direito público. Mestre em direito constitucional econômico pelo Centro Universitário Alves Faria. Doutorando em direito pelo Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa (IDP). Atualmente, é diretor de auditoria interna do TJGO.

Resumo

Unidades de auditoria interna no Poder Judiciário despendem considerável energia para produzir planos de auditoria capazes de contribuir no aperfeiçoamento da governança, em especial, quanto ao tratamento de variáveis decisórias contidas no bojo de cada objeto de auditoria. Neste trabalho, abordou-se esse processo de seleção de objetos de auditoria sob o ponto de vista da análise combinatória e propôs-se abordagem probabilística baseada em algoritmo de inteligência artificial. Como resultado, constatou-se redução considerável no tempo e esforço dos envolvidos na elaboração da lista dos objetos auditáveis. Comparou-se, ainda, com a produção de listas feita por computador empregando-se o método aleatório de produção e o algoritmo de inteligência artificial produziu soluções melhores e em menor tempo.

1 INTRODUÇÃO

Auditoria interna no Poder Judiciário goiano era um tema relativamente novo até meados de 2010, não obstante as ações operacionalizadas pela controladoria interna deste poder, em atenção ao consignado no artigo 70 da Constituição de 1988 (Brasil, 1988).

No ano de 2009, o Conselho Nacional de Justiça (CNJ) estabeleceu padrões para organização e funcionamento de unidades ou núcleos de controle interno nos tribunais, por meio da Resolução 86 (Brasil, 2009) publicada naquele ano. Apesar do avanço, essa resolução ainda não conferia a atividade de auditoria interna ao Judiciário.

Quatro anos mais tarde, as auditorias começam a ganhar vida. A Resolução CNJ n. 171

(Brasil, 2013) disciplinou a operacionalização das auditorias. Além disso, tornou obrigatória a elaboração dos planos de auditoria: Plano de Auditoria de Longo Prazo (PALP), cuja produção é quadrienal; e Plano Anual de Auditoria (PAA), elaborado anualmente.

Finalmente, em 2020, a Resolução 309 não apenas convalidou a exigência de tais planos (Brasil, 2020), mas também criou as unidades de auditoria interna que vemos hoje, na forma de unidades segregadas dos núcleos de controle interno. Apresentado o contexto histórico acerca das origens dos planos de auditoria e da própria auditoria interna no Poder Judiciário, impende afirmar que, desde 2013, as unidades de controle interno e, posteriormente, as de auditoria interna têm-se empenhado no sentido de produzir planos



de auditoria capazes de contribuir para o aperfeiçoamento da governança, bem como otimizar os processos de coleta, tratamento e resultado das variáveis decisórias contidas no bojo de cada objeto de auditoria.

Essa situação tem sido vivenciada pela unidade de auditoria interna do Tribunal de Justiça do Estado de Goiás (TJGO), a qual abordaremos nas próximas seções.

2 OS DESAFIOS DO PROCESSO DE SELEÇÃO DE OBJETOS DE AUDITORIA

Visto de relance, pode parecer trivial escolher um subconjunto de objetos de auditoria a partir de um conjunto maior. Entretanto, alguns requisitos já eram de observação obrigatória para a definição deste rol e deveriam constar nos mencionados planos de auditoria, como se nota no artigo 12 da revogada Resolução 171, a qual estabelecia:

Art. 12. Na elaboração dos Planos devem ser consideradas as seguintes variáveis:

I – materialidade – representatividade dos valores orçamentários ou recursos financeiros/materiais alocados e/ou do volume de bens e valores efetivamente geridos;

II – relevância – importância do planejamento em relação às ações a serem desenvolvidas;

III – criticidade – representatividade do quadro de situações críticas efetivas ou potenciais a ser controlado; e

IV – risco – possibilidade de algo acontecer e ter impacto nos objetivos, sendo medido em termos de consequências e probabilidades. (revogado pela Resolução 309 de 11 de março de 2020)

Visando ao cumprimento do texto normativo, um conjunto universo de objetos auditáveis foi mapeado e estabelecido no TJGO. A partir desse conjunto, planilharam-se os objetos e passou-se à fase de quantificação de cada uma das variáveis listadas na norma.

Inicialmente, o tratamento das informações era feito por meio de planilhas eletrônicas, nas quais o benefício de cada objeto auditado, obtido a partir da combinação das quatro variáveis estabelecidas no art. 12 da Resolução 171 era quantificado e, em seguida, era feita a seleção dos que obtiveram maior valor. Esse método mostrou-se inadequado, pois os objetos de auditoria com maior materialidade obtinham maiores valores e, com isso, as escolhas se tornavam enviesadas, não obstante a aplicação dos demais critérios.

Com vistas a reduzir esse efeito sobre as escolhas dos objetos de auditoria, efetuou-se a normalização das variáveis, de modo que se passou a solicitar, aos auditores, líderes que avaliassem os objetos e atribuissem uma nota que serviria de fator de avaliação. Contudo, essa iniciativa não obteve sucesso, em razão de que os auditores líderes, provenientes de diferentes áreas de conhecimento, tendiam a majorar as notas dos objetos que guardavam correlação com sua área de conhecimento.

O processo de seleção de objetos tornou-se ainda mais crítico quando se deflagrou a necessidade de inclusão de novas variáveis para atender às expectativas locais e às determinações de órgãos de controle externo, como os apontamentos prévios em sede de auditoria e as recomendações do Tribunal de Contas do estado.

Com a inclusão dessas últimas variáveis, passou-se a observar outros fenômenos decorrentes do modo de seleção de objetos. O primeiro deles foi a sobrecarga de determinada unidade auditada que, respondendo a múltiplas auditorias, tivera o desempenho da atividade afetado. De igual modo, ocorreu a sobrecarga de determinado auditor líder em um dado período, recebendo quantidade maior de auditorias em detrimento aos demais. Além disso, havia a necessidade de percorrer todos os objetivos estratégicos de maneira uniforme, bem como respeitar a carga horária máxima dos trabalhos de auditoria e acomodá-las conforme a capacidade laboral da unidade de auditoria.

Em sede de solução de contorno para essas situações, comumente eram feitas reuniões com as equipes de auditoria no sentido de reavaliar os valores atribuídos às variáveis, com fito de ajustar a situação de cada unidade auditada bem como a carga de trabalho para cada um dos líderes, o que exigia um esforço demasiado de toda a equipe.

Em paralelo, efetuaram-se buscas na literatura para identificar possíveis métodos e soluções capazes de atender aos anseios e às necessidades, de modo que abordaremos alguns deles na seção seguinte.

3 TRABALHOS CORRELATOS

O planejamento da auditoria é a primeira etapa do ciclo de auditoria interna. Nesse momento, define-se o objeto, o escopo, os recursos e o cronograma do trabalho de auditoria

a ser realizado (Menekse e Camgoz-Akdag, 2022). No Judiciário, esse momento ocorre com a seleção dos objetos de auditoria que comporão o PAA a ser executado no exercício seguinte.

O desafio de selecionar objetos de auditoria vem sendo abordado na literatura e entendido como um problema que envolve métodos de tomada de decisão multicritério, utilizados para classificar as alternativas entre várias candidatas potenciais, sujeitas a um conjunto de critérios.

Nesse aspecto, diversas propostas baseadas na aplicação de algoritmos foram apresentadas. Wang *et al.* (2022) propuseram abordagem baseada na aplicação da Matriz AHP, avaliação Fuzzy (FCE) e programação de metas de múltipla escolha ponderada. Ao final, concluíram que essa proposta é útil e as implicações do estudo podem ser estendidas a vários problemas de seleção e alocação.

Por sua vez, Menekse e Camgoz-Akdag (2021) apresentaram um modelo de eliminação e escolha traduzindo a realidade (ELECTRA) e concluíram que essa abordagem fornece uma ferramenta para tratar incertezas do processo de tomada de decisão.

Nesse ponto do trabalho, amalgamamos pontos de vista de três áreas do conhecimento, sendo que cada uma delas aborda o problema de maneira distinta: em administração, de tomada de decisão; em matemática, de análise combinatória; e o ponto central vem da área da computação: é um problema de otimização.



4 A ABORDAGEM COMPUTACIONAL

Um dos desafios para a computação moderna é obter o máximo de *performance* com o mínimo de esforço. Embora a capacidade de processamento aumente muito rapidamente, há problemas de otimização que precisam ser resolvidos, os quais a aplicação de métodos exatos não basta para resolver, devido à sua complexidade computacional.

A otimização consiste no estudo de problemas nos quais se busca minimizar ou maximizar uma função por meio da escolha sistemática dos valores de variáveis reais ou inteiras dentro de um conjunto viável. Para isso, lança-se mão de algoritmos, chamados algoritmos de otimização, que são métodos de busca cujo objetivo é encontrar uma solução ótima (Engelbrech, 2007), seja ela um ótimo local ou global.

Nessa senda, surgem os Algoritmos Genéticos (GAs), que são possivelmente o primeiro modelo algorítmico desenvolvido para simular sistemas genéticos. Engelbrech (Engelbrech, 2007) menciona em seu trabalho que os GAs foram propostos primeiramente por Fraser e, mais tarde, por Bremermann e Reed *et al.* No entanto, trabalho intensivo sobre o assunto foi realizado por Holland. Ainda de acordo com o autor, é por isso que Holland é geralmente considerado o pai dos GAs.

Algoritmos genéticos são um ramo dos algoritmos evolucionários e podem ser definidos como uma técnica de busca baseada em uma metáfora do processo biológico de evolução natural. Eles são inspirados na teoria da seleção natural proposta por Darwin em 1859 (Darwin, 1859).

A ideia principal de um GA é gerar indivíduos dentro de uma população e, em seguida, usar operadores genéticos para recombinar esses indivíduos e produzir descendentes. Dessa forma, os melhores indivíduos, que representam soluções factíveis, têm maior probabilidade de gerar descendentes, tornando as soluções melhores à medida que novos descendentes são gerados. No contexto deste trabalho, as soluções são buscadas por aproximações sucessivas, avaliando-se os progressos alcançados até que um ótimo local seja encontrado.

Algoritmos genéticos utilizam uma função objetivo para determinar a qualidade de um indivíduo como solução do problema que está sendo analisado pelo GA. Em razão da generalidade do GA, o mesmo algoritmo pode ser usado para encontrar o máximo de toda e qualquer função de n variáveis sem nenhuma alteração das estruturas de dados e procedimentos adotados, mas alterando a função objetivo (Caetano, 2013). Sendo a única ligação do algoritmo com o problema real, a função objetivo deve materializar todo o conhecimento que se possui sobre o problema, tanto suas restrições quanto seus objetivos de qualidade (Eiben, 2003).

Não obstante a abordagem de auditoria, é condição que se trata de um problema de análise combinatória, em que se pretende obter um conjunto de objetos de auditoria que respeitem um conjunto de critérios. No caso em estudo, para a aprovação do PAA, os desafios mencionados na seção anterior foram repisados e enfrentados.

Para o PAA de 2022, havia 150 objetos de auditoria e desejava-se selecionar 30 deles

para compor o referido plano. Desse modo, totalizariam aproximadamente 32 nonilhões de possíveis combinações de listas de objetos de auditoria.

Se, por um lado, seria impossível concluir a tarefa de elaborar todas as listas sem o auxílio de ferramentas computacionais, de outro, testar a qualidade de cada uma delas é proibitivo, inclusive para os computadores modernos. Eis um dos motivos pelos quais esse tipo de problema é conhecido no mundo da computação por NP-Difícil.

5 A MODELAGEM DO PROBLEMA

Para que o algoritmo faça adequadamente as recombinações, é necessário que seja feita uma modelagem matemática do problema e a tradução dele a uma função cujas propriedades dos objetos de auditoria, bem como as implicações decorrentes da recombinação deles estejam materialmente representadas.

Iniciando pelas propriedades, nessa abordagem, cada objeto de auditoria possuiu 4 ($k = 4$) propriedades (p_1, p_2, p_3 e p_4) essenciais:

1. Achados anteriores: caso um objeto de auditoria tenha sido mencionado em

um achado de auditoria anterior, ele receberá avaliação conforme o grau de relevância (baixo, médio e alto) indicado à época da auditoria.

1. Oportunidade e conveniência: diz respeito ao momento de colocar o objeto de auditoria para avaliação. Esse aspecto é importante, sobretudo quando se trata de assunto novo para a Administração, em que é preciso a implementação de providências para que seja viável a auditoria.
2. Recomendações: caso haja uma recomendação pregressa que afete o objeto de auditoria, ele receberá nota mais alta. Essas recomendações podem ser advindas de órgãos de controle externo, como Tribunal de Contas e Conselho Nacional de Justiça.
3. Risco: o risco relacionado ao objeto propriamente dito, seja ele inerente ou residual.

Cada uma das quatro propriedades foi previamente avaliada e recebeu uma nota conforme o grau de importância, variando entre zero e um. A soma das notas dessas propriedades chamaremos de Benefício (B), conforme demonstrado na equação 1.

Equação 1 – Cálculo do benefício de cada objeto de auditoria

$$B = \sum_{i=1}^k p_i$$



Em uma lista de possíveis objetos de auditoria contendo n objetos, temos que o benefício dessa lista é a soma dos benefícios individuais de cada objeto ($B_1 + B_2 + B_3 \dots B_n$).

Nesse momento, importante trazer à baila um ponto crucial no processo de seleção dos objetos para reflexão, em forma de pergunta retórica: se simplesmente ordenarem-se os objetos de auditoria conforme o benefício e selecionarem-se os que obtivessem maior valor, o benefício dos objetos selecionados seria maximizado? A resposta é um sonoro não. Isso se deve ao fato de que esse processo negligenciaria as restrições relativas às listas de objetos de auditoria mutuamente exclusivas. Essas restrições são:

- A quantidade de objetos de auditoria por unidade auditada deveria ser a mesma.
- A quantidade de objetos por auditor líder deveria ser a mesma.

- A quantidade de objetos por macrodesafio do Plano Estratégico do Poder Judiciário deveria ser a mesma.
- A quantidade de horas de trabalho para realização das auditorias não poderia exceder determinado valor.

Representando matematicamente as três primeiras restrições, sejam os conjuntos A , O e M , de modo que $\{A \cap O \cap M\}$, conjuntos de auditorias selecionados em uma lista. Cada um desses três conjuntos é formado pela união dos conjuntos dos objetos de auditoria atribuídos a cada: unidade auditada $\{A = a_1 \cup a_2 \cup \dots \cup a_n\}$, auditores líderes $\{O = o_1 \cup o_2 \cup \dots \cup o_n\}$ e macrodesafio $\{M = m_1 \cup m_2 \cup \dots \cup m_n\}$.

A última restrição é representada por H , a quantidade máxima de horas permitidas, e h a quantidade de horas calculadas para execução das auditorias. A equação 2 representa as restrições do problema.

Equação 2 – Representação matemática das restrições do problema

$$\begin{cases} A = a_1 \cup a_2 \dots \cup a_n \\ O = o_1 \cup o_2 \dots \cup o_n \\ M = m_1 \cup m_2 \dots \cup m_n \\ h \leq H \end{cases} \quad \begin{cases} : |a_1| = |a_2| = \dots |a_n| \\ : |o_1| = |o_2| = \dots |o_n| \\ : |m_1| = |m_2| = \dots |m_n| \\ : H, h > 0 \end{cases}$$

Por óbvio que a aplicação da equação 2 pode, em uma lista de objetos de auditoria, resultar em um conjunto vazio, a depender dos dados de entrada. Em sede de exemplo, considere 50 horas de auditoria como restrição H e a seleção de 10 objetos, sendo que o objeto com menor carga horária na lista é de 50 horas. Nessa situação, teríamos $h > H$ e todas as soluções alcançadas seriam infactíveis.

Visto que o algoritmo trabalha necessariamente com soluções factíveis, remediem-se as hipóteses de soluções infactíveis reparando as soluções, isto é, mudam-se objetos de auditoria na lista até que a solução se torne factível ou, na impossibilidade, aplica-se penalidade P reduzindo o benefício da solução, de modo a se obter a melhor solução maximizando a diferença entre o benefício e a penalidade. Logo, temos a função objetivo do algoritmo $f(x)$, mostrado na equação 3.

Equação 3 – Função objetivo do algoritmo

$$\text{Maximizar: } f(x) = \sum_{i=1}^n B_i - P$$

$$\text{Sujeito a: } \begin{cases} A = a_1 \cup a_2 \dots \cup a_n & : |a_1| = |a_2| = \dots |a_n| \\ O = o_1 \cup o_2 \dots \cup o_n & : |o_1| = |o_2| = \dots |o_n| \\ M = m_1 \cup m_2 \dots \cup m_n & : |m_1| = |m_2| = \dots |m_n| \\ h \leq H & : H, h > 0 \end{cases}$$

Estabelecida a função, é possível explanar os resultados obtidos pelo algoritmo.

6 O RESULTADO OBTIDO

Para evidenciar a eficácia do método aplicado, serão comparadas duas abordagens baseadas em computador, sendo a primeira por meio da produção de listas de objetos auditáveis pelo método aleatório e a segunda por meio do emprego de inteligência artificial.

Os objetos foram previamente avaliados para obtenção do benefício. As demais restrições mostradas na equação 3 foram calculadas a partir do agrupamento dos objetos em uma lista. Tentou-se, ainda, reparar a lista para tentar reduzir o efeito de penalização.

Para produção do resultado, foi requisitado que o programa de computador produzisse uma lista contendo 30 objetos de auditoria a partir de um conjunto contendo 150 objetos. Logo, o conjunto universo de possíveis listas é de 3,3E31.

Diante disso, o emprego de alguns métodos de seleção torna-se proibitivo, como a aplicação de um algoritmo de busca-cega que

pudesse testar todas as soluções. Isso se deve ao tempo necessário para conclusão da tarefa. Apenas a título de comparação, o método aleatório produziu e analisou aproximadamente 1845 soluções por segundo. Nessa velocidade, seriam necessários trilhões de anos para esgotar o rol das possíveis listas.

Não obstante, iniciamos os testes pela aplicação do método aleatório, produzindo 2 milhões de listas, separadas em 100 grupos contendo 20 mil listas cada um. Essa separação em grupos deu-se para reduzir a probabilidade de geração de soluções duplicadas. O processo de produção, reparo e avaliação das listas durou 1.084 segundos e a melhor lista produzida obteve nota 1.103.

Por outro lado, empregando IA, foram produzidas 600 mil listas e consumidos 83 segundos para realizar o processo de produção, reparo e avaliação das listas, obtendo ao final a nota de 1337. O quadro da tabela 1 resume o resultado obtido no experimento.



Tabela 1 – Quadro comparativo dos resultados

	MÉTODO ALEATÓRIO	INTELIGÊNCIA ARTIFICIAL
Tamanho da amostra	2.000.000	600.000
Máximo	1.103	1.337
Médio	1.019	1.217
Mínimo	1.003	1.130
Desvio Padrão	9,45	52,19
Tempo (s)	1.084	83
Listas / segundo	1.845,01	7.228,91

Os resultados apresentados na tabela 1 não deixam dúvida sobre a superioridade da aplicação da IA, sobretudo em razão do menor valor obtido por IA ser superior ao melhor resultado obtido pelo método aleatório, alcançando 1.130 contra 1.103. O valor médio também é superior.

A diferença de tempo também é significativa quando se comparam a quantidade de listas produzidas por segundo. Convém salientar que o tempo gasto pelo método aleatório é maior em razão da maior quantidade de soluções ineficazes por ele produzidas, fazendo que haja maior demanda por processamento para fins de reparação das soluções.

Por derradeiro, ainda que as listas geradas aleatoriamente jamais tenham sido usadas nos planos de auditoria, há que se ressaltar a dificuldade em produzir listas de objetos de auditoria empregando ferramentas computacionais comuns, tais como planilhas eletrônicas.

7 OUTRAS FUNCIONALIDADES

O módulo que executa a seleção de objetos de auditoria é parte integrante de plataforma de gerenciamento de auditorias, denomina-

da Zippy, desenvolvida utilizando Microsoft Access como *front-end* e que é capaz de administrar os trabalhos de auditoria, produzir matriz de achados, testes, relatórios, entre outros.

8 TRABALHOS FUTUROS

A abordagem atual empregou o chamado Algoritmo Genético Canônico. Em abordagens futuras, pretende-se empregar a forma híbrida combinando algoritmos de busca local, como *Hill Climbing*. Planeja-se, ainda, propor a apresentação do algoritmo integrado a outras funcionalidades da plataforma.

9 AGRADECIMENTO ESPECIAL

O conhecimento é construído a partir das experiências e interações com o meio. Contudo, sem a oportunidade e o patrocínio dos recursos apropriados, essa construção não passa de estacas cravadas em terreno arenoso. Sendo assim, nossos sinceros agradecimentos ao Dr. Aroldo Brito de Lemos que cimentou a base para a edificação do conhecimento que viabilizou a produção desta obra.

REFERÊNCIAS

BRASIL. **Constituição (1988)**. Constituição da República Federativa do Brasil.

BRASIL. **Resolução n. 171 de 01/03/2013**. Dispõe sobre as normas técnicas de auditoria, inspeção administrativa e fiscalização nas unidades jurisdicionais vinculadas ao Conselho Nacional de Justiça (Processo CNJ nº 349.544). Brasília: Conselho Nacional de Justiça, 2013.

BRASIL. **Resolução n. 309 de 11 de março de 2020**. Aprova as Diretrizes Técnicas das Atividades de Auditoria Interna Governamental do Poder Judiciário – Diraud-Jud e dá outras providências. Brasília: Conselho Nacional de Justiça, 2020.

BRASIL. **Resolução n. 86 de 8 de setembro de 2009**. Dispõe sobre a organização e funcionamento de unidades ou núcleos de controle interno nos Tribunais, disciplinando as diretrizes, os princípios, conceitos e normas técnicas necessárias à sua integração. Brasília: Conselho Nacional de Justiça, 2009.

CAETANO, S. S.; FERREIRA, D.J.; CAMILO-JR, C.C. Multi-objective genetic algorithm for competency-based selection of auditing teams. **Journal of Software & Systems Development**, v. 2013, Article ID 369217, 13 p. DOI: 10.5171/2013.369217.

CAETANO, S. S. **O uso de algoritmos evolutivos para a formação de grupos na aprendizagem colaborativa no contexto corporativo**. Dissertação de Mestrado, Universidade Federal de Goiás. 2013.

DARWIN, C. **On the origin of the species by means of natural selection**: or, the preservation of favoured races in the struggle for life. John Murray, 1859.

EIBEN, A. E.; SMITH, J. E. **Introduction to evolutionary computing**. Natural Computing Series. Springer, 2003.

ENGELBRECHT, A. P. **Computational intelligence**: an introduction. 2nd edition. Chichester, West Sussex: John Wiley & Sons, John Wiley & Sons, 2007.

MENEKSE, A.; CAMGOZ-AKDAG, H.; Internal audit planning using spherical fuzzy ELECTRE. **Applied soft computing**, v. 114, 2022, 108155, ISSN 1568-4946. Disponível em: <https://doi.org/10.1016/j.asoc.2021.108155>.

WANG, X.; FERREIRA, F.A.F.; YAN, P. A multi-objective optimization approach for integrated risk-based internal audit planning. **Ann Oper Res**. 2023, p. 1-29, Feb 14. Disponível em: doi: 10.1007/s10479-023-05228-2. Epub ahead of print. PMID: 36818190; PMCID: PMC9925941.