



A UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL -MACHINE LEARNING E BUSINESS INTELLIGENCE- NA DETECÇÃO E PREVENÇÃO DE FRAUDES CONTÁBEIS: primeiras aproximações

Lucas Souza Mendonça¹; Bruno Rodrigues Rosa²; Geraldo Sadoyama Leal³.

1. Mestrando - Programa de Pós Graduação em Gestão Organizacional- PPGGO - Universidade Federal de Catalão-GO. E-mail: Lucassouzamendonca@gmail.com
2. Mestrando - Programa de Pós Graduação em Gestão Organizacional- PPGGO - Universidade Federal de Catalão-GO.
3. Prof. Associado do Instituto de Biotecnologia e do Mestrado Profissional em Gestão Organizacional - Universidade Federal de Catalão-GO. E-mail: sadoyama@ufcat.edu.br

Recebido em: 15/08/2022 – Aprovado em: 15/09/2022 – Publicado em: 30/09/2022
DOI: 10.18677/EnciBio_2022C1

RESUMO

O presente estudo aborda a utilização de Inteligência Artificial (IA) e sua aplicação em modelos preditivos para auxílio na identificação e prevenção de fraudes. O objetivo consiste em explanar possibilidades de utilização dos recursos oferecidos na aplicação de IA em soluções de *Machine Learning* (ML) e *Business Intelligence* (BI) para aprimoramento dos processos de auditoria de empresas de médio e grande porte, através do desenvolvimento de soluções que auxiliem e/ou automatizem o processo de auditoria. A construção foi norteadada pelos seguintes questionamentos: Como o ML e BI podem auxiliar no processo de auditoria? É possível desenvolver uma solução que aprimore ou automatize a auditoria de processos, procedimentos e análise de dados contábeis das organizações? A fim de explorar o tema foram abordados os seguintes recortes temáticos: Controladoria; Auditoria; Fraudes Contábeis; Inteligência Artificial; *Machine Learning*; *Business Intelligence*. Verifica-se que a utilização de IA com diferentes metodologias complementares, como BI e ML, pode auxiliar no desenvolvimento de soluções otimizadas no mundo corporativo, como na detecção de fraudes contábeis.

PALAVRAS-CHAVE: Auditorias. *Business Intelligence*. Fraudes. Inteligência Artificial. *Machine Learning*.

THE USE OF ARTIFICIAL INTELLIGENCE (MACHINE LEARNING) AND BUSINESS INTELLIGENCE IN THE DETECTION AND PREVENTION OF ACCOUNTING FRAUD: first approximations

ABSTRACT

This study addresses the use of Artificial Intelligence (AI) and its application in predictive models to aid in the identification and prevention of fraud. Its main objective is to expose possibilities for using the resources offered in the application of AI in Machine Learning (ML) and Business Intelligence (BI) solutions to improve the auditing processes of medium and large companies, through the development of solutions that help and/or automate the process of audit. Its construction was guided

by the following questions: How can ML and BI help in the audit process? Is it possible to develop a solution that improves or automates the auditing of processes, procedures and analysis of accounting data in organizations? Constituted as a theoretical study, a group of authors were used that address the following thematic points: Controllership; Audit; Accounting Frauds; Artificial intelligence; Machine Learning; Business Intelligence. As main results, hypotheses for the development of new data analysis tools and knowledge propagation regarding the use of AI, ML and BI were postulated.

KEYWORDS: Audits. Frauds. Artificial intelligence. Business Intelligence. Machine Learning.

INTRODUÇÃO

No contexto atual, em que a evolução tecnológica atingiu novos patamares, a utilização de Inteligência Artificial em sistemas informatizados trouxe novas discussões e possibilidades. Segundo Luger (2013) a IA pode ser definida como o ramo da ciência da computação que se ocupa da automação do comportamento inteligente. Um caso prático que contextualiza a abordagem deste estudo é do projeto “Operação Serenata de Amor”, desenvolvido pelo cientista de dados Irio Musskopf. O projeto utiliza uma IA para analisar um imenso volume de dados documentais e fiscalizar os gastos da gestão pública com reembolsos efetuados pela Cota para Exercício da Atividade Parlamentar (CEAP) – verba que custeia alimentação, transporte, hospedagem entre outras atribuições consideradas necessárias para o exercício do cargo de deputado (LUGER 2013).

Partindo desta premissa obtém-se os seguintes questionamentos para sintetizar a problemática deste estudo: Como o ML e BI podem auxiliar no processo de auditoria? É possível desenvolver uma solução que aprimore ou automatize a auditoria de processos, procedimentos e análise de dados contábeis das organizações?

Para a resolução de tais questionamentos, buscou-se expor possibilidades de utilização dos recursos oferecidos na aplicação de IA em soluções de ML e BI para aprimoramento dos processos de auditoria de empresas de médio e grande porte, através do desenvolvimento de soluções que auxiliem e/ou automatizem o processo de auditoria.

Com vista ao alcance do objetivo traçado realizou-se uma apresentação de diversos conceitos e procedimentos realizados no âmbito da gestão organizacional e posteriormente apresentou-se a Inteligência Artificial. Dentre as obras utilizadas, destacam-se Luger (2013), e Mitchell (1997). Nesse sentido, este estudo se configura enquanto exploratório pautado em uma pesquisa bibliográfica, visto que compila um conjunto de definições pressupostos e abordagens de diferentes autores e busca estabelecer conexões dialógicas entre os mesmos.

Por fim, as discussões apontam que a Inteligência Artificial e as *Business Intelligence* estão em constante expansão de seus ambientes de atuação. O que se justifica por suas múltiplas aplicações que se estendem desde a execução de ações simples até a possibilidade auxílio da mão-de-obra humana nas realizações de práticas que exigem complexo grau de concentração. Além disso, as IA e BI dispõem de funcionalidades ideais ao controle de dados, permitindo com que a saúde financeira das organizações esteja melhor resguardada de tentativas de fraude.

CONTROLADORIA

Segundo Silva e Souza Junior (2018, p. 20), o departamento da controladoria surgiu no setor público inglês e, “Em seguida, alastrou-se para os Estados Unidos, através das estradas de ferro, do surgimento dos conglomerados comerciais e da participação de inúmeros acionistas em operações financeiras, atingido a iniciativa privada”.

Para Silva *et al.*, (2018, p. 67) “A controladoria tem como seu papel fundamental garantir e coordenar os esforços para que a empresa consiga atingir seu resultado global, e dar continuidade na missão da empresa para que esta possa sempre progredir na área administrativa, econômica e financeira”. Já para Marchioretto (2016, p. 252), “A controladoria é o meio pelo qual os empresários podem utilizar como ferramenta para auxiliar a gerir os recursos da empresa de forma a prestar serviços ou fornecer produtos à população de forma eficiente, para que os benefícios concedidos sejam realmente sentidos por seus usuários”.

Pode-se entender que a controladoria é um setor dentro das organizações que possui a responsabilidade de fornecer informações confiáveis e que demonstrem os cenários nos quais as empresas estão inseridas, tudo isso para que se possa tomar as melhores decisões. Nesse mesmo sentido, suas responsabilidades iniciam-se desde a coleta de dados operacionais até a apresentação/demonstração dessas informações em nível gerencial e estratégico. Em paralelo tem-se a área de Auditoria auxiliando a Controladoria, e vice e versa, na gestão e tomada de decisões (SILVA *et al.*, 2018).

AUDITORIA

A NBC TA 200 define auditoria como sendo um conjunto de procedimentos técnicos, os quais objetivam a emissão de uma opinião a respeito de determinadas demonstrações contábeis. Essas demonstrações, por sua vez, devem estar em conformidade com as normas brasileiras de contabilidade, com os princípios de contabilidade e com a legislação pertinente (CONSELHO FEDERAL DE CONTABILIDADE, 2009). Para Mendes *et al.* (2017, p. 33), “Auditoria compreende o exame de documentos e obtenção de informações e confirmações internas e externas relacionadas com o controle do patrimônio na empresa, com objetivo de concreta exatidão e dos registros contábeis”.

As auditorias possuem duas classificações: auditoria interna e externa. Auditorias internas são aquelas que contribuem tanto para a melhora dos processos nas organizações, como para a melhora das operações das mesmas, porém, isso só poderá ocorrer caso haja um certo grau de disciplina e sistematização das atividades, obtendo-se assim melhoras nos processos de controle, governanças e gerenciamentos de riscos. Nesse sentido, “O trabalho desenvolvido na auditoria interna serve como ferramenta gerencial, possibilita a eficiência dos demais controles da instituição” (DEZEN JUNIOR *et al.*, p. 294). De acordo com Silva *et al.*, (2021, p. 58527), a Auditoria Interna contribui com o gestor da organização “[...] nas tomadas de decisões através das análises, averiguações e posicionamento técnico acerca das atividades investigadas, a fim de certificar da eficiência de suas execuções e averiguar se estão em conformidade com o que foi planejado e relatado em documento”.

A auditoria externa, de acordo com Crepaldi (2019), pode ser entendida como uma série de práticas técnicas que visam emitir pareceres “[...] sobre a adequação com que estes representam a posição patrimonial e financeira, o resultado das

operações, às mutações do Patrimônio Líquido e as origens e aplicações de recursos da entidade auditada consoante as normas brasileiras de contabilidade”.

Neste sentido, a IPAI esclarece sobre a auditoria interna:

A auditoria interna é uma atividade independente de garantia e de consultoria, destinada a acrescentar valor e a melhorar as operações de uma organização. Ajudar a organização a alcançar os seus objetivos, através de uma abordagem sistemática e disciplinada, na avaliação e melhoria da eficácia dos processos de gestão de risco, de controlo e de governação. (IPAI, 2009, p. 10).

O auditor é responsável por obter uma segurança razoável de que as demonstrações financeiras, consideradas como um todo, estão isentas de distorções materiais causados por fraude ou erro (IFAC, 2012). “A função desse profissional é, além de emitir um parecer sobre as demonstrações financeiras, verificar as estruturas de controles internos, administrativos e contábeis com a finalidade de aumentar a eficiência operacional e financeira e resguardar o patrimônio” (OLIVEIRA, 2021, p. 02).

Fraudes Contábeis

De acordo com Ruiz e Zadra (2019, p. 50) “A expressão fraude tem origem no latim *fraus* e significa ação de má-fé, dolo, burla, logro. Para a contabilidade, a fraude é considerada um ato intencional de omissão ou manipulação de transações, falsificação de registros e demonstrações contábeis”. Para o IPAI (2009, p. 37), o termo fraude pode ser definido como sendo:

[...] quaisquer atos ilegais caracterizados pelo engano, encobrimento ou violação da confiança. Tais atos não dependem de ameaça de violência ou de força física. As fraudes são perpetradas por indivíduos e organizações para se apropriarem de dinheiro, bens ou serviços; para evitarem o pagamento ou perda de serviços; ou para obterem vantagens pessoais ou comerciais [...].

A ISA 240 - *The Auditor's Responsibilities Relating to Fraud in an Audit of Financial Statements*, faz a definição do termo fraude como sendo: “[...] um ato intencional praticado por um ou mais indivíduos entre a gerência, os demais encarregados da governança, os empregados ou terceiros, envolvendo o uso propositado de falsidades para obter uma vantagem injusta ou ilegal para determinado fim [...]” (IFAC, 2012, p. 160).

A prevenção e/ou a detecção de uma possível fraude é de total responsabilidade da gestão, porém, devido a isso os auditores sofrem pressões para compartilhar os resultados referentes às suas análises de dados com os gestores, isso acaba dando origem a dilemas éticos. No geral, os auditores consideram a ISA 240 como que tratando sobre fraude e a ISA 520 tratando os procedimentos analíticos referentes as problemáticas apresentadas nas áreas. Entretanto, todos sabem que a ISA 240 identifica claramente quais são os procedimentos analíticos que avaliam os riscos de fraude (IFAC, 2012).

Existem várias maneiras de se executar uma fraude, ela pode ser cometida nas organizações de forma interna, seja pelos proprietários, pelos diretores, pelos gerentes, funcionários, como também podem ocorrer externamente, tanto por fornecedores como por clientes. Esse tipo de prática pode ser definido como sendo: “o uso de uma profissão para enriquecimento pessoal por meio do uso deliberado

indevido ou da má aplicação dos recursos ou ativos da organização empregadora” (ACFE, 2016).

Assim, o atual estado de inovação tecnológica tem auxiliado na prevenção de fraudes nas organizações através da disposição de recursos que contribuem com a otimização da qualidade das informações e auxiliam o corpo gestor no processo na tomada de decisão. Dentre estes recursos, a Inteligência Artificial (IA) ocupa lugar de destaque (ACFE, 2016).

INTELIGÊNCIA ARTIFICIAL

Os conceitos e definições de IA começam a surgir logo após a Segunda Guerra Mundial. Segundo Taulli (2019), IA é o estudo de como fazer os computadores realizarem coisas que, em certo momento, as pessoas fazem melhor. Sendo uma definição efêmera ao se analisar a evolução da ciência da computação. Todavia, ao verificar outros trabalhos e bibliografias constata-se que existe um certo desconforto no meio acadêmico em conceituar o que é IA. “Afirmamos que a IA é interessante, mas não dissemos o que ela é.”. (RUSSELL; NORVIG, 2021).

Para entender o que realmente é a IA, precisa-se compreender o que é inteligência e isto se torna algo muito complexo, uma vez que estudiosos não conseguem chegar a uma definição conceitual exata. Segundo Luger (2013), mesmo que as pessoas achem que reconhecem o comportamento inteligente quando o veem, não conseguem definir a inteligência de um modo específico o suficiente para que um programa de computador possa capturar a vitalidade e a complexidade da mente humana. Porém, neste estudo, o conceito e definição utilizados são apresentados conforme segue:

A inteligência artificial (IA) pode ser definida como o ramo da ciência da computação que se ocupa da automação do comprometimento inteligente. Esta definição deve ser baseada em princípios teóricos. Esses princípios incluem as estruturas de dados usadas na representação do conhecimento, os algoritmos necessários para aplicar esse conhecimento e as linguagens e técnicas de programação usadas em sua implementação (LUGER, 2013, p. 21).

Segundo Barbosa e Bezerra (2020, p. 92), a IA “[...] se vincula à Ciência da Computação e associa-se as questões como: linguagem, inteligência, raciocínio, aprendizagem e resolução de problemas, que por sua vez perpassam os vários domínios das ciências, desde a linguística e a psicologia até a filosofia e a epistemologia”.

Neste sentido, Luger (2013, p. 22) explicita o seguinte: “[...] a inteligência artificial, como toda ciência, é um empreendimento humano e talvez seja mais bem entendida nesse contexto”. De acordo com Carvalho (2021, p. 21), um dos principais motivos para o crescimento da IA “[...] é o rápido desenvolvimento de novas tecnologias para extração, armazenamento, transmissão e processamento de dados”.

O objetivo da IA é entender e construir sistemas inteligentes, o que representa um elevado impacto em nossa cultura ocidental, uma vez que nela há crenças humanistas e especistas que nos levam a pensar que somos seres superiores e que inteligência e pensamento são dádivas exclusivas à nossa espécie - o que nos diferenciaria e nos torna superiores às demais criaturas (BARBOSA; BEZERRA, 2020, p. 92).

As aplicações de IA são muito abrangentes e, atualmente, pode-se encontrá-las nos vários seguimentos de negócio, na saúde, na educação, em finanças,

robótica, entre muitos outros. “A IA é um campo de forças em que promessas e disputas de conservação, revolução e formas de proceder estão em constante embate” (BARBOSA; BEZERRA, 2020, p. 92). Dentre suas técnicas de aplicação, este estudo irá abordar o *Machine Learning*, em razão de sua aplicabilidade e capacidade de seguir as premissas do conceito de inteligência: o aprendizado.

MACHINE LEARNING

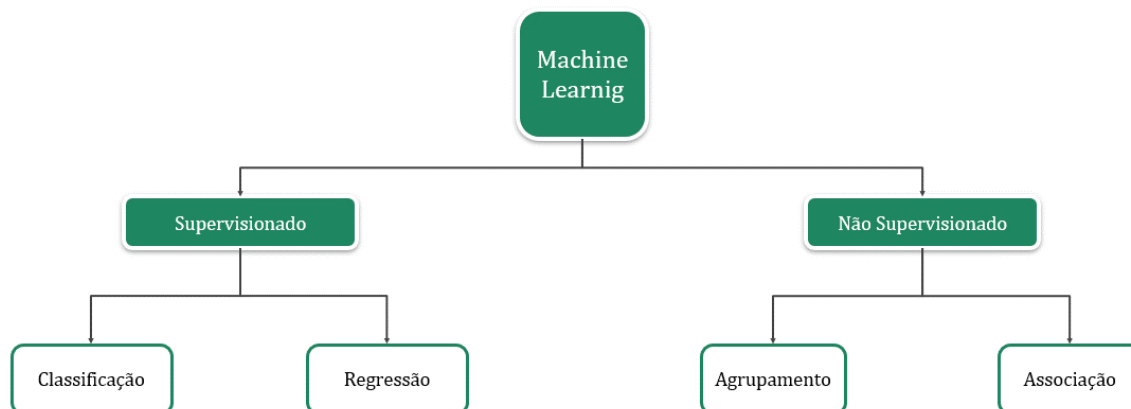
De acordo com Freitas e Santana Junior (2019, p. 08) “O Aprendizado de Máquina (AM) – do inglês, *Machine Learning* – é um dos principais pilares dessa nova era da indústria, pois permite a extração de informação utilizando dados de forma eficiente e eficaz”. Para Cerri e Carvalho (2017, p. 298) “Trata-se de uma área de pesquisa multidisciplinar que engloba inteligência artificial, probabilidade e estatística, teoria da complexidade computacional, teoria da informação, filosofia, psicologia, neurobiologia, entre outros”.

O Aprendizado de Máquina ou *Machine Learning* surgiu como uma vertente da IA para resolver problemas através da análise de dados ao automatizar a construção de modelos analíticos, utilizando várias fontes de armazenamento e, inclusive, trabalhando com *Big Data*. “O Machine Learning aborda a questão de como criar programas de computador que melhorem o seu desempenho em alguma tarefa através da experiência” (MITCHELL, 1997).

Neste contexto, o ML utiliza diversos métodos para maximizar o desempenho preditivo através de técnicas de pré-processamento de dados e ferramentas estatísticas, com os mesmos objetivos: a capacidade preditiva do modelo e de automatizar o processo de treino (PÁSCOA, 2018). Para complementar, conforme Ernesto (2018), todos os tipos de aprendizado são baseados em experiências passadas (dados) e infere algo sobre a realidade, tentando resolver um problema. Em síntese, os algoritmos de ML utilizam reconhecimento de padrões e grande volume de dados para obter respostas precisas.

Os principais tipos de ML são: supervisionado e não supervisionado. Na Figura 1 observa-se a hierarquia de aprendizado que será abordada neste estudo. Nos tópicos a seguir cada tipo de ML será explicitado.

FIGURA 1 – Hierarquia de Aprendizado do ML



Fonte: Elaborada pelos autores (2020).

O tipo supervisionado (preditivo) tem como característica a utilização de rótulos de dados do tipo: discreto, para casos de classificação (previsão de classes discretas pré-definidas); contínuos, para casos de regressão (previsão de um valor numérico contínuo). Na aprendizagem supervisionada, o agente observa alguns

exemplos de pares de entrada e saída, e aprende uma função que faz o mapeamento da entrada para a saída (RUSSELL; NORVIG, 2021), ou seja, os conjuntos de exemplos são fornecidos ao sistema com suas respectivas classes, com isto objetiva-se classificar os novos conjuntos ainda não rotulados.

Em tarefas de previsão, a meta é encontrar uma função (também chamada de modelo ou hipótese) a partir dos dados de treinamento que possa ser utilizada para prever um rótulo ou valor que caracterize um novo exemplo, com base nos valores de seus atributos de entrada e saída. [...] O termo supervisionado vem da simulação da presença de um “supervisor externo”, que conhece a saída (rótulo) desejada para cada exemplo (conjunto de valores para os atributos de entrada). Com isso, o supervisor externo pode avaliar a capacidade da hipótese induzida de prever o valor de saída para novos exemplos (FACELLI *et al.*, 2021). Os métodos mais comumente utilizados para resolver problemas de classificação e regressão são as Árvores de Decisão e Floresta Aleatória (FACELLI *et al.*, 2021).

O tipo não supervisionado (descritivo) não depende de dados rotulados e nem de um “supervisor externo” para tentar encontrar padrões em um conjunto de dados. De acordo com Ernesto (2018), “O algoritmo busca por padrões e procura saber quando a característica ocorre e quando não ocorre, ou seja, tem liberdade de classificar como quiser”.

Na aprendizagem não supervisionada, o agente aprende padrões na entrada, embora não seja fornecido nenhum *feedback* explícito. A tarefa mais comum de aprendizagem não supervisionada é o agrupamento: a detecção de grupos de exemplos de entrada potencialmente úteis. Por exemplo, um agente de táxi pode desenvolver gradualmente um conceito de “dia de tráfego bom” e “dia de tráfego ruim” sem nunca terem sido rotulados exemplos de cada um por um professor. (RUSSELL; NORVIG, 2021).

Seguindo a mesma linha de raciocínio, Luger (2013), explica:

O aprendizado não supervisionado elimina o professor e requer que o próprio algoritmo de aprendizado avalie os conceitos. A ciência talvez seja o melhor exemplo de aprendizado não supervisionado em seres humanos. Os cientistas não têm o benefício de um professor. Em vez disso, eles propõem hipóteses para explicar observações; avaliam as suas hipóteses usando critérios como simplicidade, generalidade e elegância; e testam hipóteses por meio de experimentos que eles mesmos conhecem (LUGER, 2013, p. 358).

Páscoa (2018, p. 18), pontua: “Esta abordagem é usada com dados transacionais; por exemplo, podem ser usados para identificar segmentos de clientes com atributos similares em campanhas de *marketing* e recomendar itens.”


Estrutura de Dados

A principal forma de trabalhar com ML é através de dados. De acordo com Facelli *et al.* (2021), os dados podem assumir vários formatos diferentes, tais como: séries temporais, transações, grafos ou redes sociais, textos, páginas *web*, imagens e áudios. O conjunto destes dados pode representar um objeto físico (cadeira) ou uma noção abstrata (sintomas de um paciente) que podem ser descritos por um conjunto de atributos de entrada ou vetor de característica. “O aprendizado de máquina tem uma nomenclatura própria para se referir aos dados e suas estruturas. A melhor forma de conhecer esta nomenclatura é fazendo uma analogia com uma tabela de um banco de dados.” (AMARAL, 2016). Desta forma, pode-se tomar uma tabela como uma “relação”, suas colunas “atributos” e as suas linhas como

“instâncias”. Por fim, tem-se também um atributo especial denominado “classe” ou “atributo alvo”.

Para melhor contextualizar e exemplificar a afirmação acima, deve-se observar a Tabela 1, baseada na base de dados Iris, muito utilizada na literatura de mineração de dados e de aprendizado de máquinas, proposta originalmente por Ronald Aylmer Fisher (AMARAL, 2016).

TABELA 1 – Nomenclatura de dados e estruturas



Fonte: Elaborada pelos autores (2020).

Neste sentido, Amaral (2016, p. 6) explicita o seguinte: Uma das tarefas mais comum de ML é a classificação e esta, por sua vez, possui um atributo especial que é a classe, onde: o objetivo é usar todos os atributos que compõem a relação para tentar prever a classe.

Tipos de Dados

De acordo com Camilo e Silva (2009) “Conhecer o tipo dos dados com o qual se irá trabalhar também é fundamental para a escolha do(s) método(s) mais adequado(s)”. Os principais tipos de dados são: nominais ou numéricos. Segundo Facelli *et al.* (2021), o tipo de dado define se o atributo representa quantidades, sendo então denominado quantitativo ou numérico que também podem ser contínuos ou discretos. Se o atributo apresenta qualidades, este então é denominado qualitativo, simbólico ou categórico, pois os valores podem ser associados as categorias. Para complementar, Amaral (2016) explicita:

[...] existem dois grandes grupos principais de dados: contínuos, como números reais, e nominais, que podem ser uma descrição, um nome ou uma categoria, por isso podem ser denominados também dados categóricos. Dados discretos são dados finitos, normalmente valores inteiros (AMARAL, 2016, p. 07).

Outro ponto fundamental, abordado por Facelli *et al.* (2021), destaca que uma medida quantitativa possui, além do valor numérico, uma unidade, por exemplo, metro. Se o atributo altura possui um valor qualquer, por exemplo 185, não evidencia se a altura está sendo medida em metros, centímetros ou outra unidade de medida.

Portanto, essa informação pode ser caracterizada como relevante para uma análise ou estudo.

Tarefas de Aprendizado de Máquinas

A seguir são abordadas as principais tarefas de ML, que são: classificação, regressão, agrupamento e regras de associação.

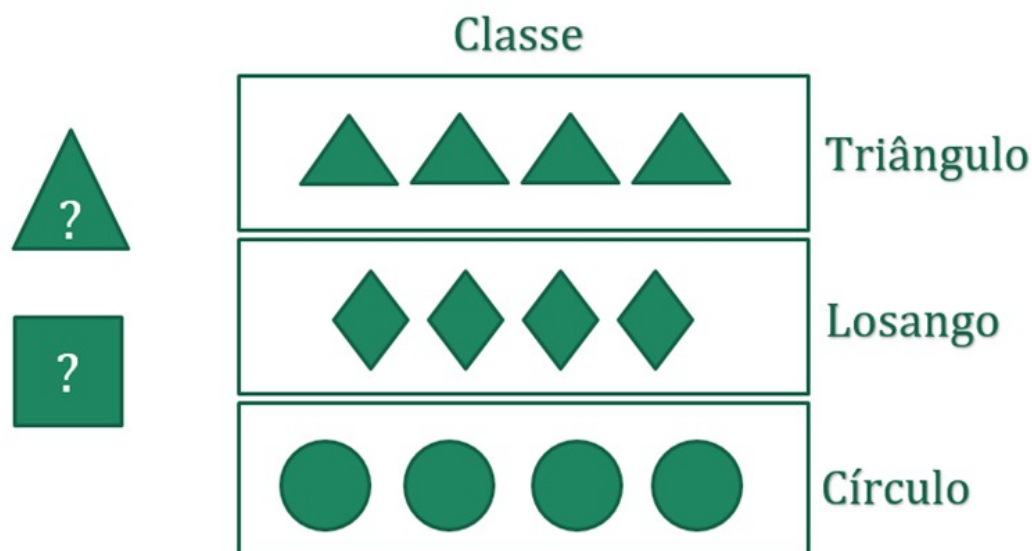
De acordo com Fonseca e Araújo Jr. (2019), não existe uma definição de qual tarefa é mais ou menos eficiente, cada caso é um caso. A clareza dos objetivos que se deseja alcançar, são os indicadores iniciais para a escolha das tarefas a serem empregadas.

Classificação

A classificação é utilizada para identificar ou descrever a classe que um determinado dado ou fato pertence. Segundo Camilo e Silva (2009), nesta tarefa, o modelo analisa o conjunto de dados fornecidos, com cada dado já relacionado à uma classe pertencente, com a finalidade de 'aprender' como classificar um novo dado. Com a classificação é possível prever uma fraude, descobrir a qual espécie um animal pertence, prever uma doença, um tipo de planta ou identificar quando uma pessoa pode ser uma ameaça para a segurança.

Neste sentido, pode-se explicitar o contexto de classificação na seguinte analogia baseada no trabalho de Amaral (2016): na Figura 2, contendo três retângulos, as formas já estão classificadas de acordo com suas classes: triângulo, losango ou círculo. As formas à esquerda com uma interrogação ao centro ainda não tiveram suas classes identificadas. O ML deve analisar quais são as características que definem cada forma e atribuí-la a uma das classes.

FIGURA 2 – Classificação de formas



Fonte: Elaborada pelos autores (2020).

Regressão

Em suma, a regressão é utilizada para estimar o valor de uma variável dependente, analisando os valores das variáveis independentes. A regressão é similar à classificação, porém é usada quando o tipo de dado é identificado por um valor numérico e não como um tipo nominal ou categórico. Por exemplo, um

conjunto de dados contendo os valores mensais gastos por diversos tipos de consumidores e de acordo com os hábitos de cada um. Após ter analisado os dados, o modelo é capaz de dizer qual será o valor gasto por um novo consumidor. (CAMILO; SILVA, 2009).

Agrupamento

O agrupamento ou *clustering* estratifica um conjunto de dados em grupos onde os elementos que compõem o grupo possuem características semelhantes. Este, por sua vez, difere da classificação pois não necessita que os dados sejam previamente categorizados.

A tarefa de agrupamento não busca classificar, estimar ou prever o valor de uma variável, ela apenas identifica grupos de dados similares. Ou seja, em agrupamentos não existem classes. O agrupamento pode ser utilizado para identificar grupos de clientes e direcionar campanhas de *marketing* específicas, identificar tentativas de acesso à rede, categorizar uma nova espécie, separar comportamentos suspeitos em auditorias entre outros (AMARAL, 2016).

Regras de Associação

A tarefa de regras de associação busca a relação entre itens e é comumente utilizada em análises de "Cestas de Compras" ou *Market Basket*. Em síntese, oferecer o produto B a quem comprar o produto A (AMARAL, 2016).

De acordo com Kurnia *et al.*, (2019), uma regra de associação é considerada interessante se atingir um valor mínimo de dois parâmetros, ou seja, suporte e confiança. Suporte é a porcentagem de itens de combinação que aparecem na base de dados (número de compras que contém todos os itens de uma combinação A e B). Confiança é a porcentagem de relacionamentos fortes entre itens (probabilidade de que quem compra o item A também compre o item B e vice-versa).

As regras de associação podem ser empregadas para identificar clientes de um plano que estão mais suscetíveis a oferta de novos serviços, mineração na *Web* ou até mesmo em bioinformática.

BUSINESS INTELLIGENCE

O *Business Intelligence* (BI) ou Inteligência de Negócio, em sua tradução literal para o português, pode ser definido como qualquer atividade, ferramenta ou processo usado para obter a melhor informação para o processo de tomada de decisão (SCHEPS, 2008). O BI busca encontrar causas, explicações, padrões para resolver problemas e alcançar objetivos, considerando um volume de dados cada vez mais complexo.

O termo BI foi cunhado pelo *Gartner Group* em meados dos anos 90. No entanto, o conceito é bem mais antigo; suas raízes remontam aos sistemas de informação gerenciais (MIS) geradores de relatórios dos anos 70. Durante esse período, estes sistemas de informação geravam relatórios estáticos, bidimensionais e sem capacidade analítica. No início da década de 1980, o conceito de EISs emergiu. Tal conceito ampliou o suporte computadorizado aos gestores e executivos do primeiro escalão (SHARDA, *et al.* 2019, p. 15).

De acordo com Lucas *et al.*, (2016, p. 172) o *Business Intelligence* (BI) e Inteligência de Negócio possuem o mesmo sentido de: “[...] conjunto de ferramentas e aplicativos que ajudam na tomada de decisões, que permitem o acesso interativo, análise e manipulação de informações corporativas de missão crítica”.

A inteligência artificial tornou-se um jargão de destaque nos negócios. No entanto, muitas organizações continuam falhando na aplicação eficaz da IA para resolver casos de negócios específicos. Uma das características importantes da IA é que ela não é estática, ela aprende e se adapta (AKERKAR, 2019). Desta forma, descreve-se a seguir como o BI pode ser integralizado com o ML para auxiliar no processo de análise, visualização de informações e na tomada de decisão em processos de auditoria.

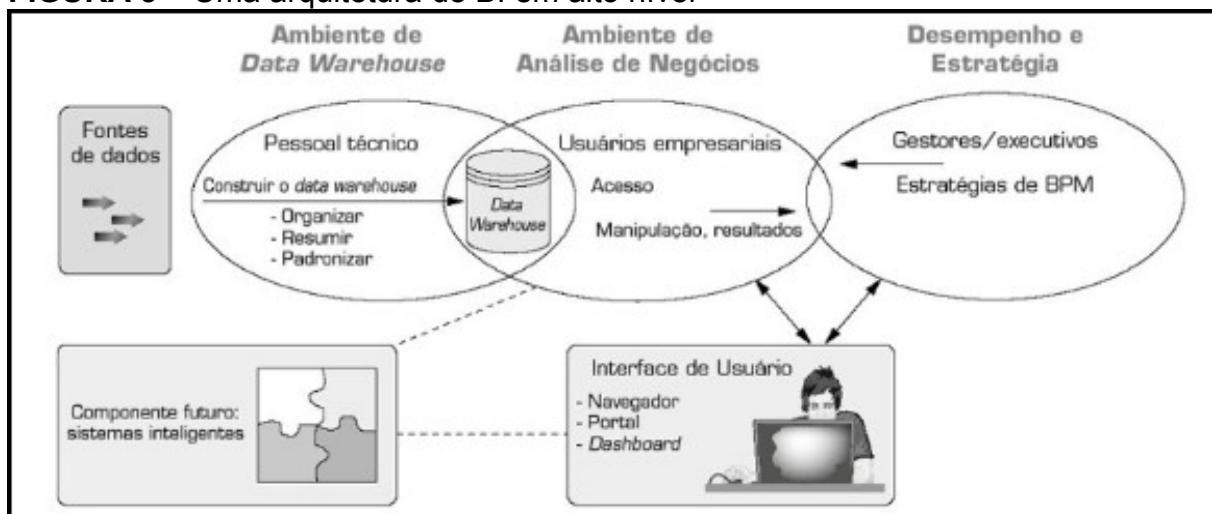
Arquitetura e componentes de BI

De acordo com Sharda *et al.* (2019), para trabalhar com BI é necessário compreender quatro importantes componentes: *Data Warehouse*, Análise de Negócio, *Business Performance Management* e Interface de Usuário. Conforme definições dos autores, tem-se:

- **Data Warehouse:** é um banco ou repositório de dados especial, preparado para dar suporte às aplicações de tomada de decisão. É construído com as metodologias, principalmente metadados e ETL (extract, transform, load);
- **Análise de Negócio:** utilizando ferramentas de *software* de interatividade chamada de *middleware* (para acessar o data warehouse), originalmente com o nome de Processamento Analítico On line (OLAP), os usuários criam relatórios e consultas sob demanda e realizarem análises de dados;
- **Business Performance Management (BPM):** é um componente final do processo de BI que se baseia na metodologia *Balanced Scorecard* (BSC). Este conecta métricas de nível superior, como as informações financeiras, aos desempenhos reais de todos os níveis hierárquicos da corporação. O BPM usa a análise, a geração de relatórios e as consultas de BI com o objetivo de otimizar o desempenho geral de uma organização;
- **Interface de Usuário:** muitas ferramentas de visualização, desde apresentações em cubo multidimensional até a realidade virtual, são parte integral dos sistemas de BI. Neste, as principais ferramentas são os *dashboards*, que fornecem uma visão abrangente e visual das medidas (indicadores-chave de desempenho), tendências e exceções do desempenho corporativo provenientes de múltiplas áreas do negócio. Os gráficos mostram o desempenho real em comparação às métricas desejadas, propiciando uma visão imediata da saúde da organização

Na Figura 3, pode-se observar a arquitetura de alto nível do BI.

FIGURA 3 – Uma arquitetura de BI em alto nível



Fonte: Sharda *et al.* (2019, p. 17).

IA - INTEGRALIZAÇÃO DE BI e ML

De acordo com Scheps (2008), o BI permite que as empresas examinem o passado, estratificando dados históricos de maneira reveladora. Mas existem aplicativos disponíveis que analisam as informações de ontem para formar previsões sobre como será o futuro. Estes *softwares* usam técnicas estatísticas avançadas para criar previsões futuras com base nos dados do passado (SHARDA *et al.* 2019).

Uma tendência em potencial envolvendo o BI é sua possível fusão com a inteligência artificial (IA). A IA tem sido utilizada em aplicações de negócios desde a década de 1980, e é amplamente usada na resolução de problemas complexos e em técnicas de suporte à decisão de aplicações de negócios em tempo real. Não levará muito tempo até a fusão entre aplicações de IA e BI, e isso dará início a uma nova era nos negócios (SHARDA *et al.*, 2019).

O ML irá fazer a tarefa que o BI não consegue realizar, a predição, como foi visto nos tópicos anteriores. Por mais que o BI consiga compilar dados e gerar informações, ele fica atrelado à análise do que já aconteceu e não consegue estimar o que possivelmente irá ocorrer no futuro. Lógico, ele entrega informação para que um agente externo (pessoa) possa tentar fazer as análises preditivas, contudo, sem chegar nem perto da capacidade preditiva que o ML consegue entregar. Por outro lado, o ML não consegue apresentar as análises e resultados alcançados com a mesma qualidade que o BI, através de suas inúmeras visualizações gráficas avançadas e *dashboards*.

CONSIDERAÇÕES FINAIS

Ressalta-se que este estudo não possuiu como objetivo o esgotamento da discussão sobre o tema. O enfoque proposto consistiu na construção de aproximações iniciais das IA e BIs enquanto instrumentos cujas funcionalidades possibilitam um controle mais criterioso e seguro de dados orçamentários das organizações com vista à prevenção de fraudes. Além disso, esses recursos são ideais para a construção de mapas históricos de evolução das instituições, dando subsídio estatístico para projeções futuras.

Ressalta-se que a utilização conjunta de ambos os recursos é fundamental para que as práticas de gestão sejam beneficiadas, afinal, enquanto as BIs possuem ampla capacidade de compilação, arquivamento e sistematização de dados, as ML desenvolvem projeções sobre possíveis efeitos futuros. As práticas de controladoria

e auditoria intermediadas por esses instrumentos permitem com que tanto gestores quanto usuários executem suas funções de forma direcionada. A expedição de *feedbacks* e a construção de materiais de apoio contribuem com a assertividade no desenvolvimento das atividades e também com a identificação de possíveis pontos de aperfeiçoamento e perigos de invasão e fraude.

Por fim, ressalta-se que, embora esses recursos ainda sejam vistos como inacessíveis no ponto de vista orçamentário, sua aplicação é válida quando considerados os resultados e as garantias dispostas.

REFERÊNCIAS

ACFE - Association of Certified Fraud Examiners, “**Report To The Nations 2016, Global Fraud Study**,” 2016. Disponível em: <<https://www.acfe.com/regional-reports/>>. Acesso em 09 de out. de 2021.

AKERKAR, R. Artificial Intelligence for Business. Library of Congress Control Number: 2018950441. **Springer International Publishing AG**, 2019. Disponível em: <<https://www.springer.com/series/8860>>. DOI: <https://doi.org/10.1007/978-3-31997436-1>. Acesso em 13 de set. de 2021.

AMARAL, F. **Aprenda mineração de dados**. Rio de Janeiro: Alta Books, 2016.

BARBOSA, X. C.; BEZERRA, R. F. Breve introdução à história da Inteligência Artificial. **Jamaxi - UFAC**, v. 4, n. 2, p. 90-97, 2020. Disponível em: <<https://periodicos.ufac.br/index.php/jamaxi/article/view/4730/2695>>. Acesso em: 18 fev. 2022.

CAMILO, C. O.; SILVA, J. C. **Mineração de Dados: Conceitos, Tarefas, Métodos e Ferramentas**. Relatório Técnico RT-INF_001-09. Instituto de Informática - Universidade Federal de Goiás, 2009. Disponível em: <http://www.portal.inf.ufg.br/sites/default/files/uploads/relatorios-tecnicos/RT-INF_001-09.pdf>. Acesso em 24 de set. de 2021.

CARVALHO, A. C. P. L. F. Inteligência Artificial: riscos, benefícios e uso responsável. **Estudos Avançados**, v. 101, n. 35, p. 21-35, 2021. Disponível em: <<https://www.scielo.br/j/ea/a/ZnKyrclVqzhZbXGgXTwDtn/?format=pdf&lang=pt>>. DOI: 10.1590/s0103-4014.2021.35101.003. Acesso em: 18 fev. 2022.

CERRI, R.; CARVALHO, A. C. P. L. F. Aprendizado de Máquina: breve introdução e aplicações. **Caderno de Ciência & Tecnologia**, v. 34, n. 3, p. 297-313, 2017. Disponível em: <<https://ainfo.cnptia.embrapa.br/digital/bitstream/item/184785/1/Aprendizado-de-maquina-breve-introducao.pdf>>. Acesso em: 19 fev. 2022.

CFC – Conselho Federal de Contabilidade. **Resolução CFC n.º 1.203 de 03 de dezembro de 2009**. Aprova a NBC TA 200 – Objetivos Gerais do Auditor Independente e a Condução da Auditoria em Conformidade com as Normas de Auditoria. CFC, Brasília, DF, 2009a. Disponível em: <http://www.cfc.org.br/sisweb/sre/detalhes_sre.aspx?Codigo=2009/001203>. Acesso em 16 de set. de 2021.

CREPALDI, S. A. **Auditoria contábil: teoria e prática**. 11. ed. São Paulo: Atlas, 2019.

DEZEN JUNIOR, R.; BEDUSCHI, D.; BORÇATO, E. C. Detectar erros e fraudes na auditoria contábil: uma análise à luz da teoria dos escândalos corporativos. **Revista Ciências Empresariais da UNIPAR**, v. 19, n. 2, p. 291-301, jul./dez. 2018. Disponível em: <<https://revistas.unipar.br/index.php/empresarial/article/download/6724/3707>>. Acesso em: 17 fev. 2021.

ERNESTO, L. **Guia de Estudos Data Science: Machine Learning**. Edição: 9 de outubro de 2018. São Paulo. Universidade de São Paulo (USP). Grupo de estudos em Data Science NEURON/USP.

FACELLI, K., LORENA, A.C.; GAMA, J.; ALMEIDA, T.A.; CARVALHO, A.C.P.F.; **Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina**. 2. ed. Rio de Janeiro: LTC - Livros Técnicos e Científicos Editora Ltda, 2021.

FONSECA, E. S.; ARAÚJO JUNIOR, C. F. A evolução do aprendizado em uma disciplina semipresencial - Análise baseada em conceitos da mineração de dados. **Brazilian Journal of Technology**, v. 2, n. 1, p. 363-382, jan./mar. 2019. Disponível em: <<https://cietenped.ufscar.br/submissao/index.php/2018/article/view/547/556>>. Acesso em 24 de set. de 2021.

FREITAS, A. L.; SANTANA JUNIOR, O. V. *Machine Learning: desafios para um Brasil competitivo*. **Revista da Sociedade Brasileira de Computação**, v. 38, n. 01, p. 07-46, 2019. Disponível em: <https://www.sbc.org.br/images/flippingbook/computacaobrasil/computa_39/pdf/CompBrasil_39_180.pdf>. Acesso em: 19 fev. 2022.

IFAC. “**ISA 240 - As Responsabilidades do Auditor Relativas a Fraude numa Auditoria de Demonstrações Financeiras**” p. 1–26, 2012. Disponível em: <<https://www.iaasb.org/publications-resources/2012-handbook-international-quality-control-auditing-review-other>>. Acesso em 09 de out. de 2021.

IPAI, “**Enquadramento Internacional de Práticas Profissionais de Auditoria Interna**,” 2009. Disponível em: <<http://www.ipai.pt/index.php>>. Acesso em 09 de out. de 2021.

KURNIA, Y.; ISHARIANTO, Y.; GIAP, Y.C.; HERMAWAN, A.; Study of application of data mining market basket analysis for knowing sales pattern (association of items) at the O! Fish restaurant using apriori algorithm. **Journal of Physics: Conf. Series** 1175, 2019. Disponível em: <<https://doi.org/10.1088/17426596/1175/1/012047>>.DOI:10.1088/17426596/1175/1/012047 Acesso em 26 de set. de 2021.

LUCAS, A.; CAFÉ, L. M. A.; VIERA, A. F. G. Inteligência de negócios e inteligência competitiva na ciência da informação brasileira: contribuições para uma análise terminológica. **Perspectivas em Ciência da Informação**, v. 21, n. 02, p. 168-187, jun. 2016. Disponível em: <<https://www.scielo.br/j/pci/a/MJWWx9hYGzFXDTzZRcJBddk/>>

format=pdf&lang=pt>. Acesso em: 18 fev. 2022.

LUGER, G. F. **Inteligência Artificial**. 6. ed. São Paulo. Pearson Brasil, 2013.

MARCHIORETTO, I. S. A Importância da Controladoria Para Os Profissionais – Uma Visão Holística Ou Ferramenta de Controle? **REPAE – Revista Ensino e Pesquisa em Administração e Engenharia**, v. 1, n. 2, p. 247-267, 2016. Disponível em: <<https://repae-online.com.br/index.php/REPAE/article/download/38/247-267/112>> Acesso em: 17 fev. 2022.

MENDES, A. P.; PACHECO, G.; LANSEN, M.V.M.; PAVAN, M.R.B.; RANGEL, M.S.A.C.; A importância da auditoria interna: estudo de caso do Supermercado Cibus. **Revista Interfaces**. Suzano, v. 9, n. 5, p. 31-52, Jul/2017. Disponível em: <http://uniesp.edu.br/sites/_biblioteca/revistas/20170705174045.pdf> Acesso em: 19 fev. 2022.

MITCHELL, T. M. **Machine Learning**. McGraw-Hill Science/Engineering/Math, 1997.

NORVIG, P.; RUSSELL, S. **Artificial Intelligence: A Modern Approach**. 4. ed. Nova Iorque. Pearson Education Limited, 2021.

OLIVEIRA, V. L. A importância da auditoria interna no processo decisório das organizações. Semana Acadêmica – **Revista Científica**. Fortaleza - CE. edição 209. v.9, 2021. Disponível em: <https://semanaacademica.com.br/system/files/artigos/artigo_veronica_oliveira_1.pdf> DOI: 10.35265/2236-6717-209-9249 Acesso em: 19 fev. 2022.

PÁSCOA, M. I. F. **Os desafios da Machine Learning: Aplicação ao Mercado Financeiro**. Universidade de Coimbra, 2018. Disponível em: <<http://hdl.handle.net/10316/84617>>. Acesso em 13 de set. de 2019.

RUIZ, S. P.; ZADRA, Â. A. Ética contábil na prevenção de fraudes. **Ensaio & Diálogos**, v. 12, n.1, p. 43-63, 2019. Disponível em: <<https://web-api-claretiano-edu-br.s3.amazonaws.com/cms/biblioteca/revistas/edicoes/6059fe9e4ea91f55e7624944/605b7fac411a529388ea4371.pdf>> Acesso em: 17 fev. 2022.

SCHEPS, S. **Business Intelligence For Dummies**. Wiley Publishing, Inc., Indianapolis, Indiana, 2008.

SHARDA, R.; DELEN, D.; TURBAN, E.; **Business Intelligence: um enfoque gerencial para a inteligência do negócio**. 4. ed. Porto Alegre. Bookman Companhia Editora, 2019.

SILVA, L. A. A.; MARCAL, M. H. L.; SARSO, F. J. H. O papel da controladoria na gestão administrativa empresarial. **Revista Eletrônica Organizações e Sociedade**, v. 07, n. 07, p. 68-86, 2018. Disponível em: <https://www.researchgate.net/publication/326564593_o_papel_da_controladoria_na_gestao_administrativa_empresaial> DOI: 10.29031/ros.v7i7.381 Acesso em: 18 fev. 2022.

SILVA, C. S.; SOUSA JÚNIOR, A. B. A importância da controladoria e da função do controller no processo de tomada de decisão na gestão empresarial. **Entrepreneurship**, v. 2, n.2, Jul./Dez, p. 17-29, 2018. Disponível em: <<http://doi.org/10.6008/CBPC2595-4318.2018.002.0002>> DOI: 10.6008/CBPC2595-4318.2018.002.0002. Acesso em: 17 fev. 2021.

SILVA, D. A.; BINDÁ, G. J.; CAVALCANTE, Z. Auditoria interna como ferramenta de gestão para prevenir e combater fraudes e erros nas organizações. **Brazilian Journal of Development**, Curitiba, v.7, n.6, p. 58517-58533 jun. 2021. Disponível em: <<https://brazilianjournals.com/index.php/BRJD/article/download/31317/pdf>> Acesso em: 19 fev. 2021.

TAULLI, T. **Artificial Intelligence Basics: A Non-Technical Introduction**. Apress; 1st ed. edição (2 agosto 2019).