



Ensaio teórico sobre o uso das redes neurais artificiais no gerenciamento de resultados

Theoretical essay on the use of artificial neural networks in earnings management

Elmo Dias da Silveira¹

Paulo Vitor Souza de Souza²

Paulo Augusto Pettenuzzo de Britto³

Resumo

A Rede Neural Artificial (RNA) tem capacidade de simular uma rede neural biológica e apresenta-se como uma ferramenta que pode auxiliar na redução de problemas econométricos mediante modelos matemáticos. Modelos de gerenciamento de resultados apresentam um problema fundamental pelo fato dos *accruals* discricionários da gestão não serem diretamente observáveis, o que vem a afetar a avaliação do desempenho real de empresas. Portanto, este ensaio tem como objetivo apresentar a RNA como uma abordagem que pode minimizar problemas observados em modelos de gerenciamento de resultados por *accruals*. A literatura sobre gerenciamento de resultados apresenta diversos problemas relacionados aos modelos por *accruals*: *proxies* não confiáveis, interpretação restrita, incentivos, existência de condições simultâneas, problemas de correlação, classificação e especificação em modelos de gerenciamento, entre outros. Com base no suporte teórico apresentado pela literatura, entende-

¹ Doutorando em Ciências Contábeis pela Universidade de Brasília (UnB), Rua GGC45, 7, Portal do Sol Green, Goiânia - GO, Brasil CEP: 74884-777. E-mail: elmodias@live.com
Orcid: <https://orcid.org/0000-0002-6869-3021>

² Doutor em Ciências Contábeis pela Universidade de Brasília (UnB), Rua Augusto Corrêa, 1, Guamá, Belém – PA, Brasil, CEP: 66075-110. E-mail: paulovsouza@ufpa.br Orcid: <https://orcid.org/0000-0001-5746-1746>

³ PhD em Economia pela University of Illinois at Urbana-Champaign; Universidade de Brasília (UnB) - Campus Darcy Ribeiro - Prédio da FACE, Asa Norte. E-mail: paulobritto@unb.br
Orcid: <https://orcid.org/0000-0001-7462-9096>

se que a utilização da abordagem da RNA pode proporcionar melhores níveis de poder e especificidade em modelos de gerenciamento de resultados por *accruals*. Este estudo visa contribuir com diversos usuários da informação contábil por evidenciar problemas em modelos de gerenciamento, bem como apresentar uma proposta baseada em inteligência artificial como solução para os problemas observados.

Palavras-chave: Gerenciamento de Resultados. *Accruals*. Redes Neurais Artificiais. *Machine Learning*.

Abstract

The Artificial Neural Network (ANN) is capable of simulating a biological neural network and is presented as a tool that can help reduce econometric problems through mathematical models. Earnings management models present a fundamental problem due to the fact that management's discretionary *accruals* are not directly observable, which affects the evaluation of the real performance of companies. Therefore, this essay aims to present ANN as an approach that can minimize problems observed in accrual earnings management models. The literature on earnings management presents several problems related to *accruals* models: unreliable proxies, restricted interpretation, incentives, existence of simultaneous conditions, correlation problems, classification and specification in management models, among others. Based on the theoretical support presented by the literature, it is understood that the use of the ANN approach can provide better levels of power and specificity in accrual earnings management models. This study aims to contribute to several users of accounting information by highlighting problems in management models, as well as presenting a proposal based on artificial intelligence as a solution to the observed problems.

Keywords: Earnings Management. *Accruals*. Artificial Neural Networks. Machine Learning.

Introdução

Quando o processo de tomada de decisões em uma empresa é atribuído a um gestor, preocupações sobre a presença de incentivos na geração de informações são recorrentes. Fama (1980) destaca que ao longo de muito tempo economistas têm se preocupado com a presença de incentivos na tomada de decisões de gestores, pois a informação gerada por estes pode não condizer com a melhor realidade das empresas.

A existência de problemas entre os participantes em um contrato originou a relação entre principal e agente. A teoria da agência determina que uma organização é concebida por uma rede de contratos, e nessa rede surge as figuras do principal e agente, mediante a ideia de que um agente é contratado pelo principal para agir de acordo com seus interesses. Porém, a relação de agência apresenta um problema, pois tanto o agente, quanto o principal buscam maximizar suas próprias utilidades e nem sempre os interesses de ambos estão alinhados (Berle & Means, 1932; Jensen & Meckling, 1976).

Os problemas da relação entre principal e agente são advindos principalmente da separação entre controle e propriedade, o que acaba resultando em limitações do principal em observar as ações dos agentes, gerando assim uma margem para que estes agentes atuem em desacordo com os interesses do principal (Subramaniam, 2006). Assim, surge a assimetria informacional, que consiste em informações em níveis diferenciados para ambas as partes de um contrato. No entanto, essa assimetria surge pelo fato de o agente ter acesso a dados que o principal não possui, o que acaba gerando uma maior possibilidade desse agente maximizar seus próprios interesses em prol dos interesses do principal (Jensen & Meckling, 1976).

Mediante o exposto, a informação contábil age como uma ferramenta que visa minimizar a assimetria de informações, e conseqüentemente os problemas de agência. Segundo Black e Nakao (2017), o processo de adoção de normas internacionais de contabilidade teve como principal objetivo melhorar a qualidade da informação fornecida pelos relatórios financeiros e demonstrações contábeis. Entende-se, portanto, que a informação contábil é de fundamental importância para a redução da assimetria informacional.

Neste contexto, relatórios financeiros de qualidade são fundamentais e observar se a informação contábil é influenciada pela gestão torna-se importante para atestar a qualidade dos lucros gerados. Assim, conforme literatura, notou-se que gestores têm se utilizado de práticas de gerenciamento de resultados (Scott, 2015). Para Healy e Wahlen (1999), os gestores utilizam julgamentos que criam oportunidades para que os resultados das entidades sejam gerenciados, mediante a escolha de métodos contábeis que não reflitam com precisão os fenômenos de uma empresa, distorcendo assim a informação fornecida pela contabilidade. Portanto, nota-se que a prática do gerenciamento de resultados afeta negativamente a qualidade da informação (Salgado & Souza, 2021), o que pode vir a interferir no aumento da assimetria informacional e na maximização da utilidade de somente uma parte em um contrato de agência.

Uma parte considerável das pesquisas sobre gerenciamento de resultados parte da premissa de que essa prática ocorre por meio da manipulação dos *accruals* de uma entidade.

A partir disso, diversos modelos buscaram dividir os *accruals* de uma entidade em uma parcela não discricionária (*accruals* normais) e discricionária (*accruals* anormais) (Jones, 1991; Dechow et al., 1995; Dechow & Dichev, 2002; Kothari et al., 2005; Francis et al., 2008). Portanto, esse campo de pesquisa passou a considerar a parcela discricionária dos *accruals* como uma medida que representa a prática do gerenciamento de resultados contábeis.

Porém, um problema fundamental do uso dos *accruals* consiste no fato do gerenciamento não ser diretamente mensurável. Deste modo, as atividades relacionadas ao gerenciamento costumam ser de difícil distinção dentro das atividades normais de uma empresa, portanto, a avaliação do desempenho real desses modelos pode apresentar problemas consideráveis. Assim, estudos como de Dechow et al. (1995), Xie (2001) e Dechow et al. (2003) questionaram a capacidade dos modelos de gerenciamento de resultados em extraírem corretamente a parte discricionária dos *accruals* contábeis.

São diversos os apontamentos sobre problemas relacionados aos modelos de gerenciamento de resultados existentes. Höglund (2012) explica que o fraco desempenho dos modelos é oriundo dos ruídos que os dados possuem. Outra explicação consiste no uso de uma abordagem linear para modelar o processo de *accruals*, o que pode prejudicar o desempenho de modelos, pois estudos sugerem que esse processo é de fato, não linear (Dechow et al., 1995; Jeter & Shivakumar, 1999; Kothari et al., 2005).

Portanto, entende-se que os diversos problemas observados em modelos tradicionais de gerenciamento de resultados podem afetar a confiabilidade deste índice como medida de qualidade informacional. Com vistas a sanar problemas relacionados a modelos de gerenciamento, o uso de uma linguagem livre de tecnicismos, explicando o pensamento racional do ser humano com precisão suficiente, seria ideal (Skansi, 2018).

Assim, o uso da máquina seria uma opção, tendo em vista que por meio da Inteligência Artificial (IA), tarefas intelectuais normalmente realizadas por humanos podem ser automatizadas (Chollet, 2018). A IA é compreendida como um campo geral que engloba o *machine learning*, o qual surgiu como um sistema onde o computador é capaz de executar e aprender por si mesmo uma tarefa específica, mediante o aprendizado automático ao observar um conjunto de dados (Chollet, 2018).

A Rede Neural Artificial (RNA) está inserida no campo do *machine learning*, sendo está compreendida como um modelo matemático que tenta simular a estrutura e funcionalidades de uma rede neural biológica, ou seja, são inseridos em uma RNA *inputs* que são ponderados, somados e ativados, gerando *outputs* que passaram por um processo de aprendizado (Krenker, Bešter, & Kos, 2011). Portanto, devido à sua adaptabilidade, a

utilização de RNA's representa diversas soluções para processamento de informações subjetivas, tomada de decisão e previsão (Sung, & Niyogi, 1994; Faller, & Schreck, 1995; Touzet, 1997), tornando-se assim, nos últimos anos, uma ferramenta para a tomada de decisões financeiras (Lam, 2004).

Como a RNA visa solucionar problemas observados em diversos campos, por meio da simulação de uma rede neural biológica, compreende-se o seu uso como uma ferramenta potencial que pode auxiliar na redução dos problemas observados em modelos tradicionais de gerenciamento de resultados ao estimar os *accruals* discricionários gerados pelo gestor. Portanto, este ensaio objetiva apresentar as Redes Neurais Artificiais (RNA) como abordagem que pode minimizar problemas observados em modelos de gerenciamento de resultados.

O presente estudo torna-se relevante por identificar diversos problemas em modelos de gerenciamento de resultados apontados por literaturas distintas, e fornecer soluções a esses problemas por meio do uso da tecnologia como ferramenta que pode reduzir a assimetria informacional existente em uma entidade. Por meio de um ensaio teórico, a contribuição potencial surge pela junção de peças teóricas em um único documento que pode auxiliar diversos pesquisadores na elaboração de trabalhos sobre a temática, bem como, sinalizar aos diversos usuários da informação que a máquina pode vir a auxiliar na detecção de práticas oportunistas da gestão.

O processo de tomada de decisão em uma empresa deve ser analisado com cautela, e a informação contábil existe com o propósito de auxiliar neste processo. Se o ser humano é capaz de manipular a informação contábil para benefício próprio, e a máquina é capaz de auxiliar na redução dessa manipulação, um estudo que faça essa ponte entre a qualidade da informação e as redes neurais artificiais pode contribuir de forma substancial para a literatura contábil.

Corpo do Ensaio Teórico

2.1 Gerenciamento de Resultados por *Accruals*

Com vistas a apresentar de forma detalhada e crítica a literatura sobre gerenciamento de resultados, utilizou-se o estudo de Dechow et al. (2010), o qual analisou mais de 300 artigos relacionados à qualidade dos lucros, os quais basearam-se no seguinte modelo clássico:

$$\text{Reported Earnings} = f(X) \quad (1)$$

No modelo apresentado, X representa a real performance financeira da empresa em um determinado período que, por sua vez, não é observável diretamente. No entanto, torna-se necessária a existência de um sistema contábil, o qual consiste em uma função do desempenho financeiro real da entidade.

Dechow et al. (2010) abordam ruídos que reduzem a capacidade do sistema contábil de representar o real desempenho financeiro de uma empresa, sendo eles: existência de múltiplos modelos de decisões; conjunto limitado e pré-definido de princípios de mensuração para um conjunto variado de modelos de desempenho financeiro; e problemas na implementação do sistema contábil (julgamentos, estimações, etc).

O aspecto relacionado à implementação do sistema contábil é apontado como uma das fontes de ruído com maior frequência. Nessa abordagem parte-se da ideia de que os *accruals* anormais afetam negativamente a utilidade da decisão, e a partir de então, busca-se isolar a sua parcela anormal, a qual pode ser interpretada tanto como erro, tanto quanto um viés, mediante os modelos de *accruals* na contabilidade (Dechow et al., 2010). Sendo assim, a qualidade dos lucros de uma empresa depende de seu desempenho real (fator não diretamente observado) e da qualidade do sistema contábil, o qual é responsável por sua mensuração.

Um princípio básico de um sistema de mensuração baseado em um regime de competência é que os lucros contábeis suavizam as flutuações relacionadas aos fluxos de caixa, fornecendo aos resultados contábeis maior capacidade informativa sobre o desempenho de uma empresa (Dechow et al., 2010). Embora pronunciamentos contábeis não afirmem que a suavização seja uma propriedade desejável dos lucros, este atributo seria o resultado de um sistema baseado em *accruals*, assumindo que estes melhoram a utilidade da decisão (Dechow et al., 2010).

Porém, desenvolver um modelo de qualidade dos *accruals* que bem separe o papel do sistema contábil e do real desempenho é um problema que nunca será resolvido por completo, tendo em vista que o real desempenho da empresa não é observável (DeFond, 2010). Além disso, o sistema contábil pode influenciar o comportamento da administração que, por sua vez, altera o valor dos lucros e, conseqüentemente, a qualidade desses lucros (Ewert & Wagenhofer, 2011).

Pesquisas que tratam de temas relacionados à persistência dos lucros, *earnings smoothing* e *accruals* anormais abordam problemas advindos das falhas de identificação do real desempenho da empresa. Ewert e Wagenhofer (2011) apontam que o *earnings smoothing* é representado tanto como uma *proxy* de gerenciamento de resultados (qualidade dos lucros

baixa), quanto como uma parcela adicional incorporada aos lucros pelos gestores (qualidade dos lucros superior).

Já no trabalho seminal de Sloan (1996), foi apontado que o menor impacto da parcela dos *accruals* na persistência dos lucros, em comparação a parcela dos fluxos de caixa, é originada de problemas no sistema contábil. Esse problema é gerado tanto pela incapacidade de refletir o real desempenho da empresa, quanto por problemas associados à discricionariedade dos *accruals*, permitidos por esse sistema.

Porém, outra explicação foi desenvolvida sobre o menor impacto dos *accruals* na persistência dos lucros. Fairfield et al. (2003) apontam que o efeito causado pelo aumento do desempenho na persistência dos lucros está pautado na observação de que, na medida em que os setores se expandem, torna-se cada vez mais difícil manter os mesmos preços para bens negociados, o que impacta negativamente nas margens de lucro, sendo assim, a menor persistência dos resultados ocorre naturalmente pela existência de retornos marginais decrescentes, e não pela qualidade informacional dos *accruals*.

De modo geral, as evidências dos trabalhos que estudam as consequências da suavização de resultados não fornecem uma conclusão clara. A variação *cross-seccional* dessa variável pode ser resultado do próprio desempenho real da empresa, da maior ou menor capacidade representativa do sistema de mensuração contábil ou da heterogeneidade das escolhas contábeis por parte dos gestores. Tais escolhas podem ter o objetivo tanto de aumentar a utilidade das decisões, quando de distorcê-las.

Portanto, torna-se necessário a separação devida desses aspectos relacionados as consequências dos *accruals* em relação à mensuração do real desempenho da empresa, pois cada um desses elementos terá implicações distintas para a utilidade da informação, que visa auxiliar o processo de tomada de decisões (Dechow et al., 2010).

2.2 Problemas Econométricos em Modelos de Gerenciamento por *Accruals*

Em estudos que visam determinar o gerenciamento de resultados em uma entidade, a questão central consiste na estimativa dos componentes gerenciados, sendo estes denominados como *accruals* discricionários ou anormais.

Kang e Sivaramakrishnan (1995) comentam que ao prever os componentes não gerenciados (*accruals* não discricionários), há uma questão metodológica relacionada a essa previsão, pois esses números contábeis serão afetados pelo próprio processo de gerenciamento. Um ponto importante a observar nos modelos de gerenciamento, é que as

medidas de *accruals* discricionários obtidas tendem a ser positivamente relacionadas com o nível de *accruals* totais (Dechow et al., 2010). Essa correlação levanta preocupações sobre se os *accruals* anormais refletem distorções contábeis ou se, em vez disso, são resultado de modelos de *accruals* mal especificados e incluem algum componente que mede o desempenho fundamental.

Portanto, Dechow et al. (2010) afirmam que os erros de classificação incorreta em modelos de *accruals* podem incluir erros do Tipo I, que classificam os *accruals* como anormais quando são uma representação do desempenho fundamental (ou seja, um falso positivo) e erros do Tipo II, que classificam os *accruals* como normais quando não são.

Algumas razões para resultados empíricos fracos e inconsistentes em modelos de gerenciamento por *accruals* são: uso de *proxies* não confiáveis para representar as parcelas gerenciadas e não gerenciadas dos lucros; foco da maioria dos estudos empíricos em um aspecto do gerenciamento de resultados por vez; interpretação restrita do gerenciamento de resultados; e incentivos dos gestores para esconder os rastros de suas ações (Sunder, 1997).

Já Arya et al. (1998) sugerem outras duas razões: os proprietários podem ter incentivos para tornar mais fácil para os gestores a ocultação de informações; e duas ou mais condições independentes que induzem o gerenciamento de resultados podem existir simultaneamente, fazendo com que estudos que se concentram em uma única condição gerem ruído em seus resultados.

Ao analisar problemas de especificação em modelos de *accruals*, Fields et al. (2001) argumentam que mesmo os trabalhos que consideram múltiplas motivações, geralmente os tratam de forma independente. Porém, na prática, os gestores enfrentam diversos conflitos em suas decisões, sugerindo assim que suas ações não são consistentes, em média. Assim, a dificuldade na especificação de uma metodologia adequada está na complexidade das atividades envolvidas, ou seja, advém do impacto simultâneo das múltiplas escolhas e objetivos, além de complicações de identificação das relações entre elas e, finalmente, dos problemas de mensuração das *proxies* escolhidas (Fields et al., 2001). De forma semelhante, McNichols (2000) reforça a dimensão do desafio enfrentado na busca da identificação e controle de potenciais variáveis omitidas correlacionadas, visto a base teórica limitada no que diz respeito ao comportamento dos *accruals* na ausência de discricionariedade.

Outro aspecto a ser observado, de fundamental importância, refere-se ao comportamento não linear dos lucros, o qual é devido a diversos fatores. Kothari et al. (2005) destacam que desempenhos extremos tendem a reverter à média, ao passo que um desempenho médio é bastante persistente, o que implica uma relação não linear entre o desempenho atual

e futuro em toda parcela da série *cross-seccional*. Outra fonte de comportamento não linear pode ser devida ao resultado da tendência dos gestores ao proceder ao uso de “*big bath*” em momentos economicamente ruins.

Outras razões que afetam negativamente o comportamento dos lucros referem-se ao conservadorismo contábil e aos incentivos para o gerenciamento dos resultados, conforme apontado pelos estudos de Watts e Zimmerman (1986), Basu (1997) e Watts (2003). Portanto, conforme observado, modelos tradicionais de gerenciamento de resultados por *accruals* são passíveis a problemas de classificação, especificação e interpretação. Assim, o uso de ferramentas para a melhor estimação dos modelos *accruals* torna-se importante com vistas a obter resultados mais próximos da realidade econômico-financeira de uma entidade.

2.3 Inteligência Artificial, *Machine Learning* e Redes Neurais Artificiais

Uma Inteligência Artificial (IA) consiste em um esforço para automatizar tarefas intelectuais que normalmente são realizadas por humanos. Portanto, a IA representa um campo geral que engloba abordagens que envolvem aprendizado, bem como engloba também outras abordagens que não envolvem aprendizado (Chollet, 2018). São diversos os ramos de aplicação da IA, e para uma melhor compreensão, esses são evidenciados na figura a seguir:

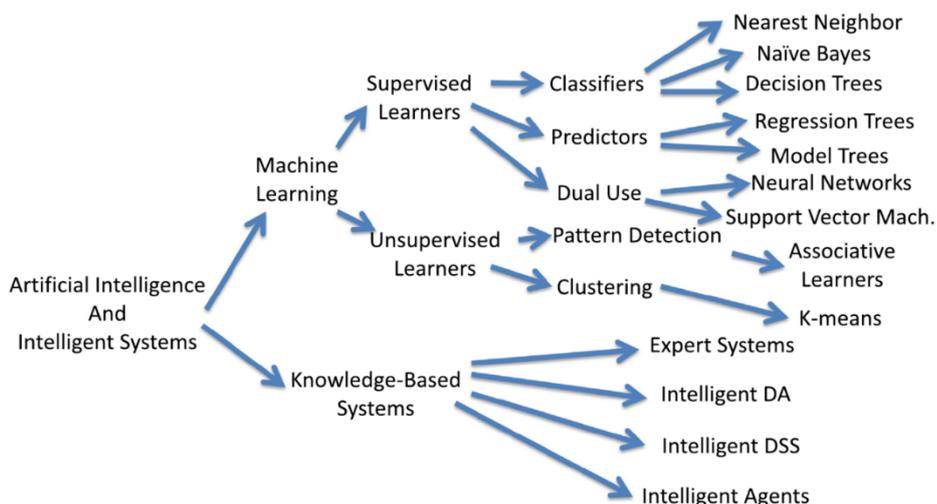


Figura 1: Ramos de aplicação da Inteligência Artificial.

Fonte: Sutton et al. (2016).

Embora a IA tenha se mostrado adequada para resolver problemas lógicos bem definidos, tais como jogar xadrez, tornou-se impraticável descobrir regras explícitas para resolver problemas mais complexos e imprecisos. Assim, uma nova abordagem surgiu para

ocupar o lugar simbólico da IA, sendo esta denominada como *machine learning* (Chollet, 2018). Ressalta-se que a IA representa um campo mais abrangente, que envolve a abordagem do *machine learning*, bem como a abordagem do *deep learning*, conforme figura a seguir:

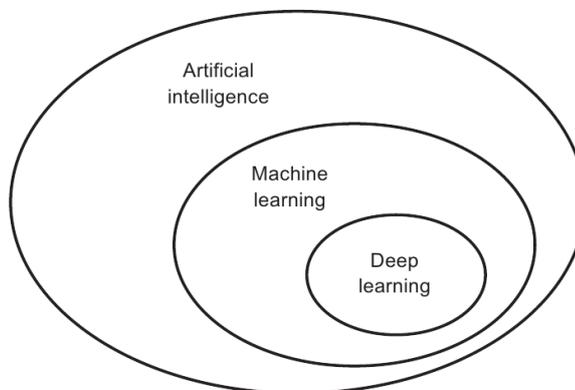


Figura 2: Campos da Inteligência Artificial.

Fonte: Chollet (2018).

O *machine learning* surgiu a partir da seguinte questão: um computador poderia ir além do que sabemos ordenar que ele execute e aprender por si mesmo como executar uma tarefa específica? Ou seja, em vez de programadores elaborando regras para o processamento de dados manualmente, busca-se descobrir se um computador poderia aprender automaticamente essas regras observando os dados (Chollet, 2018).

A questão acima apresentada abre porta para um novo paradigma de programação, pois na programação clássica, com base no paradigma da IA, um humano insere as regras de entrada, assim como dados a serem processados de acordo com essas regras, obtendo assim, um resultado com as respostas, já com o *machine learning*, os humanos inserem os dados, bem como as respostas esperadas, e como resultado, se obtêm as regras. Assim, essas regras poderão ser aplicadas a novos dados com vistas a produzir respostas originais (Chollet, 2018). Esses dois paradigmas são melhor ilustrados na figura a seguir:

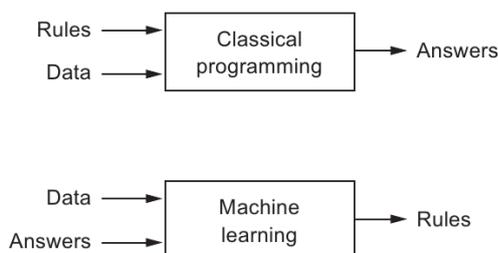


Figura 3: Programação Clássica vs Machine Learning.

Fonte: Chollet (2018).

Deste modo, um sistema baseado no paradigma do *machine learning* é treinado em vez de programado. Para tanto, torna-se necessário a apresentação de muitos exemplos relevantes para uma tarefa, para que se possa encontrar uma estrutura estatística nesses exemplos, que, eventualmente permite ao sistema criar regras para automatizar a tarefa (Chollet, 2018).

Assim, um modelo de aprendizado de máquina transforma seus dados de entrada em saídas mais significativas, pois este processo é “aprendido” a partir da exposição a exemplos conhecidos de entradas e saídas. Portanto, o problema central no aprendizado de máquina e no aprendizado profundo (*deep learning*) consiste em transformar dados de forma significativa, ou seja, aprender representações que sejam úteis na aproximação dos resultados esperados, a partir dos dados de entrada que foram disponibilizados (Chollet, 2018).

A Rede Neural Artificial (RNA) é considerada como uma das ferramentas inseridas no campo do *machine learning* e é considerada como um modelo matemático que tenta simular a estrutura e funcionalidades de redes neurais biológicas (Krenker et al., 2011). Um esquema matemático de uma rede neural artificial é evidenciado a seguir:

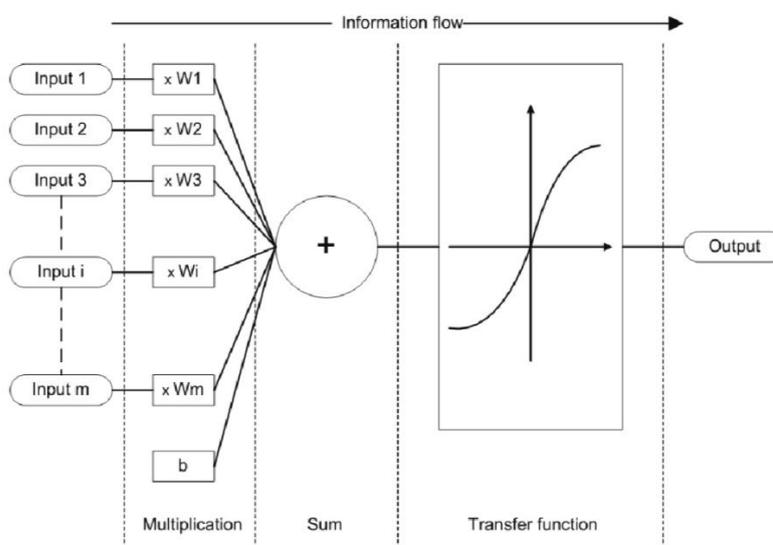


Figura 4: Esquema matemático de um Neurônio Artificial.

Fonte: Krenker et al. (2011).

A Figura 4 acima apresenta o bloco de construção básico de uma rede neural artificial (ou neurônio artificial), sendo essa composta por um modelo matemático simples (função). Neste modelo, existem três conjuntos simples de regras, sendo elas: multiplicação, soma e ativação. Na entrada do neurônio artificial, os *inputs* são ponderados, o que significa que cada *input* é multiplicado por um peso individual. Na seção intermediária do neurônio artificial, existe a função que soma todas as entradas ponderadas e o viés. Na saída do neurônio artificial,

a soma dos *inputs* previamente ponderados e do viés passa pela função de ativação, que também é chamada de função de transferência (Krenker et al., 2011).

Há diferenças a serem observadas ao se comparar um neurônio artificial (ou rede neural artificial) com um neurônio biológico. Um comparativo entre o neurônio artificial e o biológico é melhor evidenciado conforme figura a seguir:

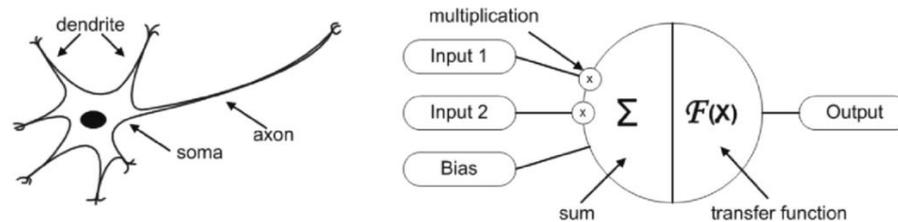


Figura 5: Neurônio biológico vs neurônio artificial.

Fonte: Krenker et al. (2011).

Em um neurônio biológico, a informação entra no dentrito (parcela do corpo neural), o corpo do neurônio (soma) processa a informação e a transmite via axônio (uma parcela do neurônio que é tipicamente mais longa que os dendritos). Já em um neurônio artificial, a informação chega por meio de entradas que são ponderadas (cada entrada pode ser multiplicada individualmente por um peso). Por seguinte, o corpo do neurônio artificial soma as entradas ponderadas e o viés, e “processa” a soma com uma função de transferência. No final, um neurônio artificial passa a informação processada via *outputs* (Krenker et al., 2011).

Mediante exposto, entende-se que uma rede neural artificial pode ser capaz de receber informações e gerar resultados que aprendem a cada rodada de dados recebidos. Assim, espera-se que essa ferramenta pode ser utilizada para corrigir alguns problemas encontrados em modelos contábeis, pois a máquina aprende por meio de vários dados que serão recebidos, ponderados e ativados.

2.4 Redes Neurais Artificiais e Gerenciamento por *Accruals*

Diversas técnicas existentes utilizadas para medir o gerenciamento de resultados tem apresentado baixo poder, devido à pouca capacidade dos modelos em isolar os *accruals* discricionários. Além disso, testes realizados com essas técnicas são incorretamente especificados devido a variáveis omitidas em amostras com desempenho financeiro extremo, situação não incomum em testes de gerenciamento de resultados (Dechow et al., 2012).

Assim, as Redes Neurais Artificiais (RNA) apresentam algumas vantagens que podem ser utilizadas em modelos de gerenciamento de resultados. Em primeiro lugar, uma RNA

possui a capacidade de “aprender” e desenvolver um mapeamento de qualquer estrutura não-linear complexa. Em segundo lugar, uma RNA não exige a determinação de suposições *a priori* sobre a distribuição dos dados analisados. E por fim, em terceiro lugar, pode-se enfatizar o alto nível de flexibilidade no que diz respeito a dados incompletos, ausentes e com alto grau de ruído (Vellido et al., 1999).

Portanto, conseqüentemente, uma RNA possui características importantes na superação dos principais problemas associados aos modelos tradicionais na detecção do gerenciamento de resultados e tem o potencial de desenvolver modelos de predição para identificar o nível do gerenciamento de resultados. Assim, a primeira questão de pesquisa é baseada na possível superioridade da metodologia proporcionada pela abordagem das Redes Neurais Artificiais em relação ao método da regressão, conforme segue:

Questão 1: A utilização das Redes Neurais Artificiais proporciona maiores níveis de poder e especificidade em modelos de detecção de gerenciamento de resultados do que a utilização das abordagens baseadas em regressão linear?

Um aspecto de suma importância a ser discutido sobre modelos de gerenciamento de resultados é descrito por Scott (2015). Uma lei fundamental (*iron law*) deste processo é baseada no regime de competência, onde torna-se necessária a reversão dos *accruals*. Portanto, sempre que ocorre um gerenciamento positivo dos lucros, a um valor maior do que pode ser sustentado, a reversão desses *accruals* em períodos subsequentes forçará os lucros para baixo.

Em contrapartida, os *accruals* não discricionários estão vinculados às operações subjacentes aos negócios da empresa. Tais *accruals* tendem a se originar em períodos de crescimento das operações, ou quando ocorrem mudanças estratégicas em decisões operacionais e/ou de investimento (McNichols, 2000).

Baseando na perspectiva de que as empresas operam em um contexto de continuidade, suas características operacionais tendem a persistir, assim como os *accruals* não discricionários relacionados. Assim, de forma geral, a reversão de *accruals* não discricionários tende a ser compensada por outros de mesma natureza, exibindo, de forma agregada, persistência ao longo do tempo (Dechow et al., 2012).

Assim, baseado nessa lei, Dechow et al. (2012) propuseram um procedimento para abordar os problemas associados às técnicas tradicionais, incorporando as informações dos pesquisadores sobre a reversão dos *accruals* discricionários. Esta abordagem pode ser

adaptada para utilização em todos os modelos tradicionais de gerenciamento de resultados com base em *accruals*.

Porém, Dechow et al. (2012) destacam que este procedimento requer que os períodos em que se espera que os *accruals* sejam manipulados sejam identificados previamente, assim como os de expectativa de suas reversões. Assim, uma questão de pesquisa pode estar relacionada a verificar se utilização da RNA para a determinação de tais períodos promove melhores no poder e especificidade do modelo inicial, conforme segue:

Questão 2: A utilização das Redes Neurais Artificiais na determinação dos períodos de início da manipulação dos *accruals*, assim como dos períodos de reversão, melhora o poder e especificidade do modelo proposto por Dechow et al. (2012)?

Com relação à não linearidade constante em modelos tradicionais de gerenciamento de resultados, Kothari et al. (2005) destacam que, a menos que os modelos de *accruals* discricionários sejam adaptados para lidar com este problema, não há razão para esperar que a abordagem de regressão seja eficaz no controle de *accruals* discricionários diferentes de zero em amostras estratificadas aleatórias. Os autores evitaram a superação deste problema por meio de modelos de regressões não lineares, justificando a escolha com base na ausência de uma teoria para orientar tal modelagem, o que implica na necessidade de testar uma quantidade de especificações acima do razoável, além de poder gerar problemas relacionados ao *overfitting*.

A escolha metodológica do estudo de Kothari et al. (2005), em contraste com a abordagem de regressão, foi baseada no confronto da parcela discricionária dos *accruals* das empresas do mesmo segmento, com base em suas performances (*performance matched approach*). Esta abordagem assume que, em média, as empresas do grupo de tratamento e de controle têm os mesmos *accruals* discricionários não relacionados ao evento estudado (performance).

Assim, entende-se que o poder do modelo de Kothari et al. (2005) reside na capacidade em determinar, de forma razoável, a melhor seleção para os grupos de controle e tratamento na detecção do gerenciamento de resultados. Portanto, a terceira e última questão de pesquisa pode ser delineada conforme segue:

Questão 3: A utilização das Redes Neurais Artificiais na determinação dos grupos de controle e tratamento, melhora o poder e especificidade do modelo proposto por Kothari et al. (2005)?

As questões de pesquisa abordadas nesta seção possuem como intuito direcionar pesquisadores, principalmente, na a utilização de RNAs para a melhora do poder e especificidade de modelos tradicionais de gerenciamento de resultados, com uma ênfase nos modelos de Kothari et al. (2005) e Dechow et al. (2012) por esses serem os modelos mais contemporâneos propostos. Espera-se que as discussões aqui apresentadas possam fornecer um suporte a diversos estudiosos sobre problemas observados nos modelos tradicionais e direcionem a possibilidades de uso de métodos mais complexos para correção desses problemas.

Considerações Finais

A assimetria de informação entre participantes em um contrato de agência tem gerado, ao longo do tempo, diversas discussões acerca da maximização de interesse entra uma das partes de um contrato. Assim, a informação gerada pela contabilidade tem potencial de minimizar essa assimetria, principalmente quando esta informação é gerada com qualidade.

Porém, a gestão de uma empresa tem adotado a prática do gerenciamento de resultados de informações contábeis, mediante julgamentos e escolha de métodos que acabam não refletindo de forma precisa os fenômenos de uma empresa, prejudicando assim a qualidade da informação gerada pela empresa (Healy & Wahlen, 1999), agravando assim a assimetria, ao invés de minimizá-la.

Diversos estudiosos desenvolveram modelos que visam mensurar a parcela gerenciada do lucro contábil, com vistas a obter um valor que represente uma medida confiável sobre um possível oportunismo da gestão, porém, o uso dos *accruals* para mensurar esse gerenciamento tem apresentado problemas, por diversos apontamentos realizados em trabalhos anteriores (Dechow et al., 1995; Jeter & Shivakumar, 1999; Xie, 2001; Dechow et al., 2003; Kothari et al., 2005; Höglund, 2012).

Modelos tradicionais de gerenciamento de resultados apresentam: problemas de especificação em modelos; comportamento não linear dos lucros; conservadorismo contábil; presença de incentivos; variáveis omitidas, entre outros. Portanto, torna-se necessário que

formas de melhor estimação de modelos de *accruals* sejam implementadas com vistas a se obter uma melhor medida de representação da realidade econômica da empresa.

Portanto, este trabalho apresentou a Rede Neural Artificial (RNA) como uma ferramenta que pode corrigir problemas apresentados pelos modelos tradicionais de gerenciamento de resultados. Vellido et al. (1999) apresenta três vantagens do uso da RNA em modelos de gerenciamento de resultados: capacidade de aprender e desenvolver um mapeamento de qualquer estrutura não-linear complexa; não exigência na determinação de suposições sobre a distribuição dos dados; e alto nível de flexibilidade no que diz respeito a dados incompletos. Portanto, essa ferramenta pode apresentar uma saída aos problemas observados nesses modelos contábeis de gerenciamento de resultados.

Foram delineadas três questões de pesquisa que representam possíveis efeitos do uso de RNAs nos modelos de gerenciamento de resultados por *accruals*: a utilização de RNAs pode proporcionar maiores níveis de poder e especificidade em modelos de gerenciamento de resultados do que a utilização das abordagens baseadas em regressão linear; a utilização das RNAs na determinação dos períodos de início da manipulação dos *accruals*, assim como dos períodos de reversão, melhora o poder e especificidade do modelo proposto por Dechow et al. (2012); e a utilização das RNAs na determinação dos grupos de controle e tratamento, melhora o poder e especificidade do modelo proposto por Kothari et al. (2005).

Assim, pode-se observar que essa ferramenta tecnológica possui um poder de melhor apurar os *accruals* em comparação aos modelos tradicionais de gerenciamento de resultados, mediante maior nível de poder e especificidade, bem como na melhor determinação dos períodos de início e reversão, e grupos de controle e tratamento de modelos amplamente conhecidos e utilizados.

Espera-se que este trabalho possa contribuir com uma maior instigação ao uso de ferramentas computacionais na apuração de valores não diretamente observáveis pela contabilidade, bem como no incremento de discussões sobre o uso de ferramentas tecnológicas para solucionar problemas econométricos observados em modelos que apuram a qualidade da informação contábil. Assim, espera-se que haja uma melhora na apuração dessas variáveis não diretamente observáveis, bem como um avanço nos estudos relacionados aos temas sobre gerenciamento de resultados e qualidade da informação contábil, mediante a integração da ciência contábil com a tecnologia da informação.

Este trabalho limita-se por centrar-se somente no uso de Redes Neurais Artificiais como única ferramenta possível que possa solucionar os problemas observados em modelos tradicionais de gerenciamento, tendo em vista que no ramo da Inteligência Artificial existem

diversos outros métodos. Porém, justifica-se pela oportunidade de explorar uma ferramenta importante de forma mais profunda, com maior aplicação na correção de problemas observados nesses modelos de gerenciamento por *accruals*. Assim, sugere-se para pesquisas futuras uma ampliação das ferramentas advindas da Inteligência Artificial em modelos de qualidade da informação contábil.

Referências

- Arya, A., Glover, J., & Sunder, S. (1998). Earnings management and the revelation principle. *Review of Accounting Studies*, 3(1–2), 7–34. <https://doi.org/10.1023/a:1009631714430>
- Basu, S. (1997). The conservatism principle and the asymmetric timeliness of earnings. *Journal of Accounting and Economics*, 31(3), 3–37. <https://doi.org/10.1177/0962280211413449>
- Berle, A. A., & Means, G. G. C. (1932). The Modern Corporation and Private Property. In *The Modern Corporation and Private Property (First)*. Harcourt, Brace & World, Inc. <https://doi.org/10.4324/9781315133188>
- Black, R., & Nakao, S. H. (2017). Heterogeneidade na qualidade do lucro contábil entre diferentes classes de empresas com a adoção de IFRS: evidências do Brasil. *Revista Contabilidade e Finanças*, 28(73), 113–131. <https://doi.org/10.1590/1808-057x201702750>
- Chollet, F. (2018). Deep Learning with Python (First). *Manning Publications Co.*
- Dechow, P., & Dichev, I. D. (2002). The Quality of Accruals and Earnings: The Role of Accruals Estimation Errors. *The Accounting Review*, 77(2002), 35–59. <https://doi.org/10.2308/accr.2002.77.s-1.61>
- Dechow, P., Ge, W., & Schrand, C. (2010). Understanding earnings quality: A review of the proxies, their determinants and their consequences. *Journal of Accounting and Economics*, 50(2–3), 344–401. <https://doi.org/10.1016/j.jacceco.2010.09.001>
- Dechow, P. M., Hutton, A. P., Kim, J. H., & Sloan, R. G. (2012). Detecting Earnings Management: A New Approach. *Journal of Accounting Research*, 50(2), 275–334. <https://doi.org/10.1111/j.1475-679X.2012.00449.x>
- Dechow, P. M., Richardson, S. A., & Tuna, I. (2003). Why Are Earnings Kinky? An Examination of the Earnings Management Explanation. *Review of Accounting Studies* 2003 8:2, 8(2), 355–384. <https://doi.org/10.1023/A:1024481916719>
- Dechow, P. M., Sloan, R. G., & Sweeney, A. P. (1995). Detecting Earnings Management. *The Accounting Review*, 70(2), 193–225. <https://doi.org/10.2307/248303>
- DeFond, M. L. (2010). Earnings quality research: Advances, challenges and future research. *Journal of Accounting and Economics*, 50(2–3), 402–409. <https://doi.org/10.1016/j.jacceco.2010.10.004>
- Ewert, R., & Wagenhofer, A. (2011). Earnings Management, Conservatism, and Earnings Quality. *Foundations and Trends in Accounting*, 6(2), 65–186. <https://doi.org/10.1561/14000000025>

- Fairfield, P. M., Whisenant, S., & Yohn, T. L. (2003). The Differential Persistence of Accruals and Cash Flows for Future Operating Income versus Future Profitability. *Review of Accounting Studies*, 8(2), 221–243. <https://doi.org/10.1023/A:1024413412176>
- Faller, W. E., & Schreck, S. J. (1995). Real-Time Prediction of Unsteady Aerodynamics: Application for Aircraft Control and Maneuverability Enhancement. *IEEE Transactions on Neural Networks*, 6(6), 1461–1468. <https://doi.org/10.1109/72.471362>
- Fama, E. F. (1980). Agency Problems and the Theory of the Firm. *Journal of Political Economy*, 88(2), 288–307. <https://doi.org/10.1086/260866>
- Fields, T. D., Lys, T. Z., & Vincent, L. (2001). Empirical research on accounting choice. *Journal of Accounting and Economics*, 31(1–3), 255–307. [https://doi.org/10.1016/S0165-4101\(01\)00028-3](https://doi.org/10.1016/S0165-4101(01)00028-3)
- Francis, J., Olsson, P., & Schipper, K. (2008). Earnings Quality. *Foundations and Trends in Accounting*, 1(4), 259–340. <https://doi.org/10.1561/1400000004>
- Healy, P. M., & Wahlen, J. M. (1999). A Review of the Earnings Management Literature and Its. *Accounting Horizons*, 13(4), 365–383. <https://doi.org/10.2308/acch.1999.13.4.365>
- Jensen, M. C., & Meckling, W. H. (1976). Theory of the firm: Managerial behavior, agency costs and ownership structure. *Journal of Financial Economics*, 3(4), 305–360.
- Jeter, D. C., & Shivakumar, L. (1999). Cross-sectional estimation of abnormal accruals using quarterly and annual data: effectiveness in detecting event-specific earnings management. *Accounting and Business Research*, 29(4), 299–319. <https://doi.org/10.1080/00014788.1999.9729590>
- Jones, J. J. (1991). Earnings Management During Import Relief Investigations. *Journal of Accounting Research*, 29(2), 193. <https://doi.org/10.2307/2491047>
- Kang, S. H., & Sivaramakrishnan, K. (1995). Issues in Testing Earnings Management and an Instrumental Variable Approach. *Journal of Accounting Research*, 33(2), 353. <https://doi.org/10.2307/2491492>
- Kothari, S. P., Leone, A. J., & Wasley, C. E. (2005). Performance matched discretionary accrual measures. *Journal of Accounting and Economics*, 39(1), 163–197. <https://doi.org/10.1016/j.jacceco.2004.11.002>
- Krenker, A., Bešter, J., & Kos, A. (2011). Introduction to the Artificial Neural Networks, In: Suzuki K (ed), Artificial Neural Networks: Methodological Advances and Biomedical Applications. *InTech*, 1–18. <http://www.intechopen.com/books/artificial-neural-networks-methodological-advances-and-biomedical-applications/introduction-to-the-artificial-neural-networks>
- Lam, M. (2004). Neural network techniques for financial performance prediction: integrating fundamental and technical analysis. *Decision Support Systems*, 37(4), 567–581. [https://doi.org/10.1016/S0167-9236\(03\)00088-5](https://doi.org/10.1016/S0167-9236(03)00088-5)
- McNichols, M. F. (2000). Research design issues in earnings management studies. *Journal of Accounting and Public Policy* 19(4–5). [https://doi.org/10.1016/S0278-4254\(00\)00018-1](https://doi.org/10.1016/S0278-4254(00)00018-1)
- Salgado, N. de N. B., & Souza, P. V. S. de. (2021). The Effect of Accounting Timeliness on Earnings Management for Brazilian Companies Listed on B3. *Advances in Scientific*

- and Applied Accounting*, 14(1), 039–055 / 056.
<https://doi.org/10.14392/asaa.2021140102>
- Scott, W. R. (2015). *Financial accounting theory* (Seventh). Pearson Canada Inc.
- Skansi, S. (2018). *Introduction to Deep Learning*. In *Deep Reinforcement Learning: Fundamentals, Research and Applications*. <https://doi.org/10.1007/978-3-319-73004-2>
- Sloan, R. G. (1996). Do Stock Prices Fully Refelct Information in Accruals and Cash Flows About Future Earnings? *The Accounting Review*, 71(3), 289–315.
- Subramaniam, N. (2006). Agency theory and accounting research: an overview of some conceptual and empirical issues. In Z. Hoque (Ed.), *Methodological issues in accounting research: theories and methods*, 55–81. Spiramus Press.
- Sunder, S. (1997). *Theory of Accounting and Control*. South-Western College Publishing.
- Sung, K., & Niyogi, P. (1994). *Active Learning for Function Approximation*. In G. Tesauro, D. Touretzky, & T. Leen (Eds.), *Advances in Neural Information Processing Systems* (Vol. 7). MIT Press.
<https://proceedings.neurips.cc/paper/1994/file/acf4b89d3d503d8252c9c4ba75ddb6d-Paper.pdf>
- Sutton, S. G., Holt, M., & Arnold, V. (2016). The reports of my death are greatly exaggerated. Artificial intelligence research in accounting. *International Journal of Accounting Information Systems*, 22, 60–73. <https://doi.org/10.1016/j.accinf.2016.07.005>
- Touzet, C. F. (1997). Neural reinforcement learning for behaviour synthesis. *Robotics and Autonomous Systems*, 22(3–4), 251–281. [https://doi.org/10.1016/S0921-8890\(97\)00042-0](https://doi.org/10.1016/S0921-8890(97)00042-0)
- Vellido, A., Lisboa, P. J. G., & Vaughan, J. (1999). Neural networks in business: a survey of applications (1992–1998). *Expert Systems with Applications*, 17(1), 51–70. [https://doi.org/10.1016/S0957-4174\(99\)00016-0](https://doi.org/10.1016/S0957-4174(99)00016-0)
- Watts, R. L. (2003). Conservatism in Accounting Part I: Explanations and Implications. *Accounting Horizons*, 17(3), 207–221. <https://doi.org/10.2308/ACCH.2003.17.3.207>
- Watts, R. L., & Zimmerman, J. L. (1986). *Positive Accounting Theory*. Prentice-Hall Inc.
- Xie, H. (2001). The Mispricing of Abnormal Accruals. *The Accounting Review*, 76(3), 357–373. <https://doi.org/10.2308/ACCR.2001.76.3.357>

Submetido em: 16.12.2022

Aceito em: 19.01.2023