

Inteligência computacional aplicada ao controle externo: classificação de padrões utilizando redes neurais artificiais.



Renan Martins de Sousa

é servidor do Tribunal de Contas da União, graduado em Engenharia Elétrica pela Universidade Federal do Ceará (UFC) e especialista em regulação de serviços de telecomunicações pelo Instituto Nacional de Telecomunicações (Inatel) e União Internacional de Telecomunicações (UIT).

RESUMO

O aumento da demanda por maior transparência das informações custodiadas por órgãos públicos tem levado à crescente disponibilização de diversas bases de dados. Esse fato, aliado aos avanços na capacidade de processamento, tem despertado o interesse pelo uso da inteligência computacional em áreas ainda pouco exploradas, como as atividades de auditoria vinculadas ao controle da administração pública. A habilidade das redes neurais artificiais para classificar padrões pode ajudar os órgãos de controle a desempenhar suas competências de forma mais eficiente. Aplicações típicas da classificação de padrões na área de auditoria estão relacionadas à detecção de fraudes, auditoria de demonstrações contábeis e avaliação de risco, dentre outras. O Tribunal de Contas da União (TCU), atento a essa realidade, vem realizando diversas ações para desenvolver habilidades associadas à análise de dados.

Palavras-chave: Inteligência computacional aplicada; Redes neurais; Classificação de padrões; Auditoria; Tribunal de Contas da União.

1. INTRODUÇÃO

Os avanços tecnológicos observados nas últimas décadas, tanto no que diz respeito à capacidade de processamento computacional quanto à capacidade de



armazenamento de dados, aliados à crescente disponibilização de informações, lança um desafio enorme àqueles que precisam tratá-las e emitir uma opinião com base nesse tratamento.

Segundo Byrnes et al. (2014), a ciência de dados, da mesma forma, tem avançado enormemente, incorporando teorias, técnicas e aplicações de software de muitas disciplinas, incluindo a análise de dados, inteligência de negócios, matemática e probabilidade, aprendizado estatístico (incluindo o reconhecimento de padrões), visualização de dados e a análise e tratamento de grandes conjuntos de dados, a exemplo da mineração e visualização de dados.

A aplicação dessas teorias pode ser aproveitada pelos órgãos de controle, a fim de que eles possam apresentar novos tipos de evidências e realizar auditorias mais focadas, podendo resultar em opiniões mais fidedignas sobre os objetos de auditoria, mesmo quando submetidos a requisitos severos de performance, como tempo, precisão e custo.

Este artigo conceitua a classificação de padrões como ferramenta da inteligência computacional aplicada e apresenta, resumidamente, as origens, características e treinamento das redes neurais artificiais, em especial da rede perceptron multicamadas (MLP), exemplificando a sua utilização no campo da auditoria. Além disso, informa como o Tribunal de Contas da União (TCU) tem incentivado o tratamento de bases de dados informacionais para tornar sua atuação mais efetiva, tempestiva e inteligente.

2. O QUE SIGNIFICA CLASSIFICAR PADRÕES?

O reconhecimento automático, a descrição, o agrupamento e a classificação de padrões são ferramentas muito importantes para uma grande variedade de disciplinas da engenharia e das ciências, como biologia, psicologia, medicina, visão computacional, inteligência artificial e sensoriamento remoto, entre outras.

Mas o que são padrões? Jain, Duin e Mao (2000 apud Watanabe, 1985, p. 1) definem um padrão como “o oposto ao caos; é uma entidade para a qual pode ser atribuído um nome”. A título de exemplo, um padrão pode ser um sinal de voz, uma amostra de DNA, um documento de texto, um vídeo, uma impressão digital, uma palavra escrita à mão etc.

De posse do padrão, seu reconhecimento (ou classificação) pode ser realizado de forma não supervisionada ou supervisionada. Na primeira, o padrão é associado a uma classe até então desconhecida, técnica conhecida como *clustering*. Nesse caso, o problema é de categorização, no qual as classes são definidas pelo projetista do sistema ou são aprendidas com base na similaridade dos padrões. Na segunda, de maior interesse para este artigo, o padrão é identificado como sendo parte de uma classe pré-definida. A separação de padrões entre as classes pode ser realizada por meio da análise de discriminantes.

Exemplos de aplicações nesse campo incluem *data mining*, classificação de documentos, previsões financeiras, organização e busca em bancos de dados multimídia e biometria, entre muitas outras.

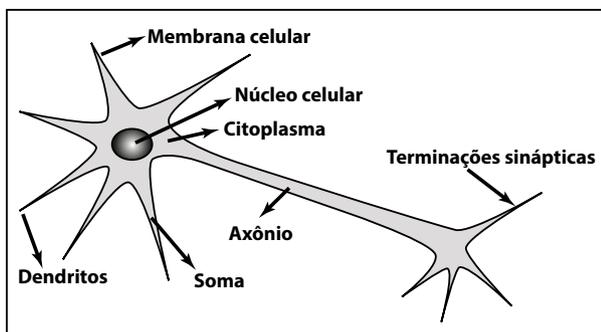
Em resumo, o reconhecimento de padrões é o estudo de como máquinas podem observar o ambiente, aprender a distinguir padrões de interesse e tomar decisões confiáveis e razoáveis sobre as categorias desses padrões.

O projeto de um sistema de reconhecimento de padrões envolve três macroetapas fundamentais: (i) aquisição de dados e pré-processamento; (ii) representação dos dados; e (iii) tomada de decisão. De modo geral, o domínio do problema é quem dita a escolha do método aplicado em cada uma dessas etapas. Os modelos mais utilizados para tomada de decisão em reconhecimento de padrões são: encaixe no molde (*template matching*), encaixe estrutural (*structural matching*), classificação estatística e redes neurais artificiais.

3. AS REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais são sistemas de processamento numérico compostos pela conexão de uma grande quantidade de processadores simples. Essas in-

Figura 1:
Neurônio típico



Fonte: <http://blogdopetcivil.com/2013/07/05/redes-neurais-artificiais/>

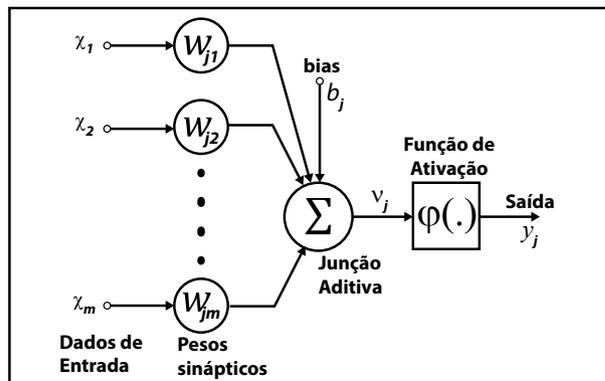
terconexões têm inspiração biológica, a saber, no sistema nervoso dos seres vivos. O conceito subjacente a esses sistemas é o de que processamentos complexos podem ser obtidos quando são combinados muitos processadores simples, altamente interconectados, conhecido na literatura como conexionismo.

O conexionismo, que se utiliza de um processamento distribuído e paralelo, em contraposição ao processamento centralizado, representa com alguma facilidade as características dos processos cognitivos, como a capacidade de considerar, simultaneamente, diversas restrições, ou de combinar diversas fontes de conhecimento. Consegue representar, além disso, a capacidade de generalização.

Ainda que tenham inspiração biológica, os modelos de redes neurais atualmente existentes não representam aspectos e estruturas amplamente conhecidos da fisiologia cerebral, como a organização espacial dos neurônios e das interconexões e a existência de variados tipos de sinais entre esses “processadores”. Isso se deve à busca do equilíbrio entre a plausibilidade biológica dos modelos e seu tratamento matemático.

As figuras abaixo ilustram a visão esquemática de um neurônio típico (Figura 1) e uma abstração para fins computacionais (Figura 2):

Figura 2:
Modelo não-linear de um nó da rede neural



Fonte: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1806-11172011000100009



Os fundamentos do atual modelo de neurônio e do princípio da associação datam do final do século XIX, nos trabalhos de James (1890). Porém, somente na primeira metade do século XX apareceram os primeiros estudos importantes em relação à capacidade matemática de redes de elementos processadores inspirados em neurônios. McCulloch e Pitts (1943) demonstraram que associações desses neurônios artificiais podiam implementar qualquer função lógica finita, o que pode ser considerado o primeiro sucesso teórico do conexionismo.

Porém, o passo mais importante quanto ao tema foi dado quando Rosenblatt (1958) introduziu o primeiro modelo neural concreto, chamado de perceptron, que inicialmente tinha apenas duas camadas: entrada e saída. Esse modelo conseguia aprender a classificar padrões a partir de exemplos, mas seu uso foi prejudicado por algumas limitações, expostas no trabalho de Minsky e Papert (1969), causando uma descontinuidade das pesquisas. O ressurgimento do interesse no conexionismo ocorreu com o uso do algoritmo de treinamento por retropropagação do erro (*errorbackpropagation*), apresentado por Rumelhart e McClelland (1986). Isso permitiu a extensão do perceptron de Rosenblatt para várias camadas (*multilayer perceptron* – MLP), superando as limitações do modelo original e permitindo o desenvolvimento de aplicações em diversos ramos do conhecimento.

Feito esse breve histórico, faz-se necessário situar as redes neurais artificiais dentro do universo de méto-

dos aplicáveis ao reconhecimento de padrões e descrever algumas de suas principais características.

Embora existam diversas abordagens para o reconhecimento de padrões, somente são de interesse para este artigo as abordagens estatística e neural. Esta tem diferentes princípios de funcionamento, embora se utilize de modelos equivalentes aos daquela.

Na abordagem estatística, cada padrão é representado por um conjunto de “n” características— ou medidas— e visualizado como um ponto no espaço n-dimensional. Segundo Jain, Duin e Mao (2000), o objetivo dessa representação é escolher as características de modo que os padrões (vetores de características) pertencentes a diferentes classes ocupem regiões compactas e bem ordenadas do espaço n-dimensional de características. Assim, a efetividade dessa escolha é maior quanto mais fácil é separar os padrões pertencentes às diversas classes.

Com base em um subconjunto de padrões das variadas classes (*training set*), o objetivo da abordagem estatística é definir fronteiras de decisão no espaço n-dimensional de características que seja capaz de separar padrões que pertençam às diferentes classes. Na abordagem estatística, as fronteiras de decisão são determinadas pelas distribuições de probabilidade dos padrões, que devem ser conhecidas ou aprendidas *a priori*.

A abordagem neural, por outro lado, se utiliza da análise de discriminantes não lineares, que é uma análise geométrica. As funções discriminantes são construídas

pela combinação linear de funções não lineares básicas, tendo a seguinte forma:

$$g(\mathbf{x}) = \sum_{i=1}^m w_i \varphi_i(\mathbf{x}, \mathbf{u}_i) \quad (1)$$

A combinação de \mathbf{x} e do vetor de parâmetros \mathbf{u} é um produto escalar, ou seja, $\varphi_i(\mathbf{x}, \mathbf{u}_i) = \phi_i(\mathbf{x}^T \mathbf{u}_i)$. A forma da função não linear ϕ , chamada de função de ativação, é escolhida *a priori*, e o procedimento de otimização determina, ao mesmo tempo, os parâmetros w_{ij} e \mathbf{u}_i . Em outras palavras, são escolhidas previamente as funções base, mas seus parâmetros são adaptáveis durante a fase de otimização.

Em suma, as principais características das redes neurais são: (i) habilidade para aprender relações não lineares entre entradas e saídas; (ii) utilização de procedimentos de treinamento sequenciais; e (iii) capacidade de adaptação aos dados apresentados.

4. REDE PERCEPTRON MULTICAMADAS, APRENDIZADO E O ALGORITMO DE RETROPROPAGAÇÃO DO ERRO (ERRORBACKPROPAGATION)

De acordo com Bishop (2006), o modelo mais bem sucedido que utiliza a abordagem neural, no contexto do reconhecimento de padrões, é a rede neural MLP, de interesse para este artigo. Uma rede neural é especificada, principalmente, pela sua topologia, pelas características de seus nós e pelas regras de treinamento.

As redes MLP são organizadas em camadas, ligadas por conexões unidirecionais, como mostra a Figura 3.

O modelo matemático de uma rede MLP, tal qual a apresentada na Figura 3, pode ser representado pela seguinte fórmula:

$$y_k(\mathbf{x}, \mathbf{w}) = \sigma \left(\sum_{j=0}^M w_{kj}^{(2)} h \left(\sum_{i=0}^D w_{ji}^{(1)} x_i \right) \right) \quad (2)$$

Na equação (2), as funções de ativação σ^* e h^* geralmente tomam a forma da função sigmóide, dadas as suas características de representar um mapeamento não linear entre entrada e saída e de ser diferenciável, embora outras formas sejam admitidas, a depender da aplicação.

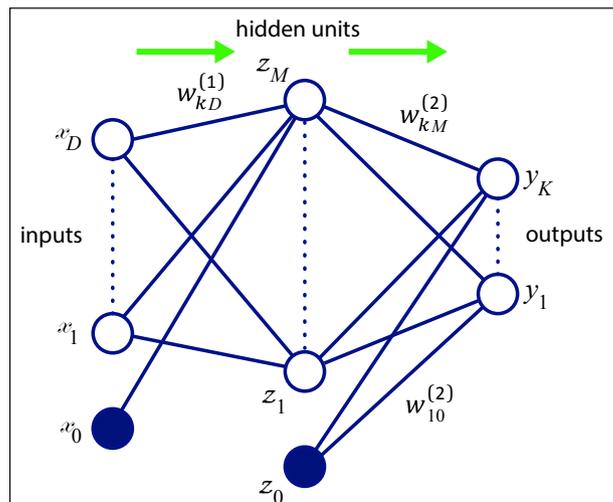
A combinação linear $\sum_{i=0}^D w_{ji}^{(1)} x_i$, após passar pela transformação não linear h^* , é recebida como entrada nos neurônios da camada escondida. Esse resultado é combinado linearmente com os pesos $w_{kj}^{(2)}$ e submetidos a uma nova transformação não linear σ^* , resultando na saída y_k .

Em resumo, a rede MLP é um mapeamento não linear de um conjunto de variáveis de entrada $\{x_i\}$ para um conjunto de variáveis de saída $\{y_k\}$, controlado por um vetor de parâmetros ajustáveis \mathbf{w} , conhecidos como pesos sinápticos.

O procedimento de aprendizagem (otimização) envolve a atualização dos parâmetros $w_{kj}^{(2)}$ e $w_{ji}^{(1)}$, de modo que a rede neural possa realizar a tarefa de classi-

Figura 3:

Arquitetura de uma rede MLP com uma camada escondida e uma camada de saída



Fonte: Bishop (2006)
[Legenda: *inputs* = entradas; *hidden units* = neurônios da camada escondida; *outputs* = saídas]

ficação de forma eficiente. No caso da rede MLP, a regra de otimização mais utilizada e difundida é aquela definida pelo algoritmo de retropropagação do erro.

Durante o treinamento com esse algoritmo, a rede opera em uma sequência de duas etapas. Primeiro, um padrão – conjunto de variáveis $\{x_i\}$ – é apresentado à camada de entrada da rede. O processamento é realizado através da rede, camada por camada, até que a resposta seja produzida pela camada de saída, em um processo iterativo.

Assim, o passo inicial da primeira etapa envolve o cálculo do nível de ativação e das saídas de todos os neurônios da camada escondida e da camada de saída. As saídas dos neurônios da camada escondida fazem o papel de entrada para os neurônios da camada de saída. Em seguida são calculadas as saídas dos neurônios da camada de saída.

Na segunda etapa, a saída obtida é comparada com a saída desejada para o padrão apresentado, pois a saída desejada já se conhece *a priori*. Se a saída obtida não estiver correta, calcula-se o erro (diferença entre as saídas desejada e obtida), o qual é propagado a partir da camada de saída até a camada de entrada, em sentido inverso. Os pesos das conexões das camadas escondidas vão sendo modificados conforme o erro é retropropagado, utilizando a regra delta generalizada, cuja explicação minuciosa refoge ao escopo deste artigo.

Essa etapa envolve o cálculo dos gradientes locais dos neurônios da camada de saída – $\delta_k(t)$ – e da camada escondida – $\delta_i(t)$ – e o ajuste dos pesos de todos os neurônios.

O segundo passo corresponde à atualização dos pesos sinápticos da rede MLP. Dessa forma, para a camada escondida a regra de atualização dos pesos $w_{ji}^{(1)}$ para a próxima iteração é dada por:

$$w_{ji}^{(1)}(t+1) = w_{ji}^{(1)}(t) + \nabla w_{ji}^{(1)}(t) = w_{ji}^{(1)}(t) + \alpha \delta_i(t) x_j(t) \quad (3)$$

Para a camada de saída, a regra de atualização dos pesos $w_{kj}^{(2)}$ é a seguinte:

$$w_{kj}^{(2)}(t+1) = w_{kj}^{(2)}(t) + \nabla w_{kj}^{(2)}(t) = w_{kj}^{(2)}(t) + \alpha \delta_k(t) y_k(t) \quad (4)$$

Nas equações (3) e (4), “ α ” é um dos parâmetros de entrada do algoritmo, conhecida como taxa de aprendizagem.

Em suma, quando um padrão é inicialmente apresentado à rede, ela produz uma saída. Após medir a distância entre a resposta atual e a desejada (erro), são realizados os ajustes apropriados nos pesos das conexões de modo a reduzir essa distância. Depois que a rede estiver treinada e o erro atingir um nível satisfatório, ela poderá ser utilizada como uma ferramenta para classificação de novos dados.

O projeto de uma rede neural e o funcionamento desse algoritmo envolve a especificação de uma série de parâmetros que influenciam decisivamente o seu funcionamento, sua convergência e a capacidade de generalização da rede. Essas são considerações que também não se situam no escopo deste artigo.

O exemplo a seguir ilustra, de forma bastante intuitiva, qual o problema que as redes neurais artificiais do tipo MLP, como classificadores de padrões, buscam resolver. Suponha uma base de dados¹ que contenha informações de um determinado gênero de flor, chamada Íris. Essa base de dados é composta dos seguintes atributos (características) desse gênero de flor: largura da pétala, comprimento da pétala, largura da sépala e comprimento da sépala. A depender dos valores dessas características, a flor é classificada em uma de três espécies (classes): *iris virginica*, *iris setosa* ou *iris versicolor*. A base de dados tem vários registros e cada um deles associa o conjunto de atributos da flor à sua respectiva espécie, como ilustra a tabela abaixo:

Tabela 1: Exemplo de apenas três registros de uma base de dados utilizada pela rede neural MLP

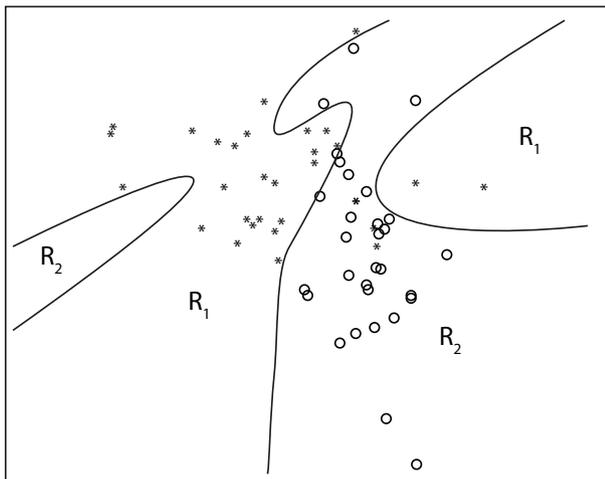
Fonte: elaboração própria

Sépala		Pétala		Espécie
Comprimento (cm)	Largura (cm)	Comprimento (cm)	Largura (cm)	
4,8	3,4	1,6	0,2	<i>Iris setosa</i>
6,2	2,2	4,5	1,5	<i>Iris versicolor</i>
6,9	3,1	5,4	2,1	<i>Iris virginica</i>

A rede neural do tipo MLP é treinada com parte desses registros aleatoriamente escolhidos (*training set*), ou seja, apresenta-se à rede o conjunto de dados de entrada (atributos) e a respectiva classe da flor, com a finalidade de que a rede neural aprenda com esses dados. Após o treinamento, a rede neural passa a ser capaz de classificar, entre uma das espécies da flor, um novo padrão (conjunto dos quatro atributos da flor) que a ela se apresente, com determinada taxa de acerto.

Para que se tenha uma visualização gráfica da solução de classificação de uma rede neural do tipo MLP, a Figura 4 apresenta as fronteiras ideais de separação de duas classes de padrões, representados pelos símbolos “*” e “o”.

Figura 4 – Fronteiras de decisão (R_1 e R_2) de uma rede neural MLP para classificação de padrões de duas classes



Fonte: Jain, Duin e Mao (2000)

5. APLICAÇÃO DA CLASSIFICAÇÃO DE PADRÕES POR MEIO DAS REDES NEURAS ARTIFICIAIS AO DOMÍNIO DA AUDITORIA

Ainda que não seja tão frequente, quando comparado a outros ramos do conhecimento, a utilização de redes neurais no campo da auditoria encontra diversos registros na literatura científica, ainda que as referências aqui citadas não sejam resultantes de uma exaustiva revisão.

Calderon e Cheh (2002) analisam estudos publicados em algumas categorias: avaliação de riscos (três estudos), identificação de fraudes e erros (seis estudos), emissão de opinião do tipo *goin gconcern*^{II} (três estudos), identificação de situações de demasiada exposição a riscos financeiros (três estudos) e previsão de falência (doze estudos). Para esses autores, as redes neurais podem ser superiores a outras técnicas quando os dados estão disponíveis em grandes amostras, a escala de valores a serem analisados é grande e associações entre os dados são pouco definidas e pouco perceptíveis.

Garrity, O'Donnell e Sanders (2006), ao defenderem a auditoria contínua e o uso da inteligência computacional, também destacam aplicações de redes neurais artificiais nas mesmas áreas apontadas por Calderon e Cheh (2002) e Koskivaara (2003).

Cerullo e Cerullo (2006) analisam o uso de redes neurais para prever a presença de fraudes em demonstrações financeiras, utilizando-se de coeficientes e informações da análise das próprias demonstrações contábeis. Os autores afirmam que as redes neurais processam grandes quantidades de dados para resolver problemas pelo reconhecimento de tendências e de relacionamentos complexos e pouco perceptíveis para outros métodos computacionais.

Taha (2012) justifica o uso de redes neurais ao domínio da auditoria e conclui que as redes neurais são melhores do que os métodos estatísticos para o planejamento e execução de auditorias. Na visão desse autor, as redes neurais podem apontar as demonstrações financeiras com maior chance de conter erros substantivos, orientando o auditor sobre a profundidade dos testes de auditoria e oferecendo mais condições de que seja emitida uma opinião mais fidedigna sobre essas demonstrações.

Pourheydari, Nezamabadi-Pour e Aazami (2012) utilizaram quatro técnicas de classificação de padrões para identificar opiniões modificadas^{III} e não modificadas^{IV} de auditoria sobre demonstrações financeiras. Embora esse estudo apresente outras conclusões bastante interessantes, seus resultados mostraram que a rede neural do tipo MLP provou ter alta capacidade de identificar diferentes tipos de opinião de auditoria das demonstrações contábeis, obtendo uma taxa de acerto de mais de 87%, considerando as opiniões modificadas e não modificadas em conjunto.

Por fim, Byrnes et al. (2014) defendem a apropriação das técnicas de análise de dados pelos padrões de auditoria. Na visão dos autores, a evolução tecnológica, a exemplo da computação em nuvem, e o avanço



da ciência de dados fornecem subsídios para o aumento da efetividade e da eficiência dos trabalhos de auditoria. Defendem que a incorporação da inteligência computacional permitiria a realização de auditorias contínuas e preditivas, a detecção de fraudes de forma mais efetiva e a emissão de opinião de forma mais segura.

Os mesmos autores apontam ainda diversas oportunidades que são potencializadas pelo uso da análise de dados em auditorias financeiras, como: identificação de riscos associados a contratos de auditoria (riscos de falência e fraudes da alta administração); identificação de riscos de erros materiais e realização de testes substantivos e identificação de desconformidades das demonstrações contábeis devido a fraudes.

Essas aplicações são aderentes, quase que em sua totalidade, aos trabalhos realizados pelos órgãos de controle. Ademais, o reconhecimento de padrões, utilizando-se de redes neurais artificiais, pode ser utilizado em diversos outros problemas de auditoria, como, por exemplo, a identificação de fraudes em processos licitatórios e em concessão de benefícios de programas governamentais, identificação de atos de pessoal (admissão, aposentadoria e pensão) inaptos a registro, bem como ferramenta para auditoria contínua e preditiva do Balanço Geral da União, objeto da análise anual das contas de governo da Presidência da República. Portanto, o uso de redes neurais pode se revelar um instrumento importante para aprimorar a efetividade,

a eficiência e até a economicidade dos trabalhos realizados por essas instituições.

6. FOMENTANDO O USO DA INTELIGÊNCIA COMPUTACIONAL NO EXERCÍCIO DO CONTROLE EXTERNO

Já é consolidado o entendimento de que compete ao TCU não somente o controle de legalidade e conformidade, mas também o controle de eficiência, economicidade, eficácia e efetividade dos atos de gestão daqueles que utilizam, arrecadam, guardam, gerenciam ou administram dinheiros, valores e bens públicos.

Para realizar o controle externo em todas as suas dimensões, o TCU tem recebido diversas competências por meio de normas constitucionais e infraconstitucionais. Essas competências, ao longo do tempo, têm se tornado bastante complexas e variadas, demandando uma atuação tempestiva, focada e inteligente do TCU, de forma a otimizar os recursos postos à sua disposição.

A sociedade, cada vez mais conectada e consciente da necessidade de maior transparência no uso dos recursos públicos, tem demandado, de forma crescente, a disponibilização de bases de dados governamentais. Nesse contexto, o TCU tem se deparado, muitas vezes, com a necessidade de manipular adequadamente essas informações e utilizá-las a fim de auxiliar a sua missão de aprimorar a Administração Pública em benefício da sociedade.

Foi nesse cenário que a Presidência do TCU, durante a gestão do Ministro Aroldo Cedraz, decidiu empreender ações que fomentem o uso da inteligência computacional aplicada ao controle.

Dois direcionadores estratégicos definidos para o Planejamento Estratégico 2015-2021 do TCU, aprovado pela Portaria-TCU 141, de 1º de abril de 2015, destacam-se nesse contexto: (i) usar inteligência de controle para identificar em larga escala riscos de inexecução ou execução inadequada de produtos e serviços e induzir tais práticas aos demais jurisdicionados; e (ii) desenvolver capacidade organizacional ampla para trabalhar com recursos tecnológicos emergentes e analisar grandes bases de dados (*Big Data*).

No nível tático, o Plano de Controle Externo referente ao biênio 2015-2017 define uma linha de ação aderente a esse movimento, qual seja, a de fiscalizar, de forma contínua, a partir do tratamento de dados de bases informacionais, a utilização de recursos públicos, com vistas a detectar e corrigir tempestivamente possíveis desvios.

Uma destacada iniciativa associada a esse movimento foi a inauguração, em 28 de setembro de 2015, do Centro de Pesquisa e Inovação (CePI) do TCU. Essa unidade, que já havia iniciado suas atividades em janeiro de 2015, tem por finalidade fomentar a pesquisa aplicada no TCU e coordenar o Laboratório de Inovação e Coparticipação (coLAB-i).

O coLAB-i tem o objetivo de apoiar projetos inovadores, garantir a gestão do conhecimento de soluções desenvolvidas, coordenar ações de cooperação e promover ações de capacitação e eventos em assuntos na fronteira do conhecimento. Além disso, o coLAB-i, primeiro laboratório de inovação em um órgão de controle, teve o privilégio de já entrar para o seleto grupo que consta no mapa mundial de laboratórios da Nesta (<http://www.nesta.org.uk/>) no seu primeiro ano de vida.

Além disso, o TCU tem promovido seminários e cursos de capacitação em análise de dados e a premiação, por intermédio do programa Reconhe-Ser, de diversos projetos que aplicam ferramentas da ciência de dados.

7. CONCLUSÃO

O rápido crescimento da capacidade de processamento computacional e da disponibilidade de grandes bases de dados facilitaram o uso de métodos mais elaborados de análise e classificação de dados. Nesse contexto, as técnicas de reconhecimento de padrões, a exemplo das redes neurais artificiais, ganharam destaque em aplicações nos mais variados ramos do conhecimento.

As redes neurais artificiais são sistemas de processamento numérico formados por unidades de processamento altamente conectadas e capazes de mapear relacionamentos não lineares presentes em grandes bases de dados. Utilizando-se da teoria da análise de discriminantes não lineares e do algoritmo de retropropagação do erro para treinamento e otimização de seus parâmetros, as redes neurais do tipo perceptron multicamadas são capazes de generalizar o conhecimento adquirido e classificar padrões com altas taxas de acerto.

A classificação de padrões com o uso de redes neurais pode auxiliar os órgãos de controle em todas as etapas de suas auditorias, seja na fase de planejamento, de execução ou de relatório. Diversos estudos têm apresentado aplicações em avaliação de riscos, identificação de fraudes e erros, avaliação de continuidade (emissão de opinião do tipo *going concern*), identificação de situações de demasiada exposição a riscos financeiros, previsão de falência, identificação de opiniões modificadas e não modificadas de auditoria sobre demonstrações financeiras, entre outras. O campo de aplicação é vasto e ainda pouco explorado.

A atividade de controle externo, em particular, tem como insumo e produto a informação e o conhecimento, elementos cada vez mais dependentes da tecnologia da informação. O tratamento de dados, para deles extrair informações, é, portanto, condição indispensável para alavancar as atividades de controle em uma sociedade cada vez mais conectada.

O TCU, atento a essa realidade e à necessidade de tornar a sua atuação cada vez mais focada, tempestiva e inteligente, tem incentivado o uso da ciência de dados aplicada ao controle externo, por meio de diversas ações constantes de seu Planejamento Estratégico e de seu Plano de Controle Externo. Merece destaque a inauguração, em 28 de setembro de 2015, do Centro de Pesquisa e Inovação (CePI).

NOTAS

- I Base de dados disponível em <<https://archive.ics.uci.edu/ml/datasets/Iris>>.
- II Também conhecida como avaliação de continuidade. Consiste na análise do fluxo de caixa de curto e médio prazo de uma operação, negócio ou empresa. Suporta decisões estratégicas de curto prazo com base na geração de caixa e liquidez do negócio. Serve para revelar o fôlego financeiro da empresa para os próximos meses e decidir sobre financiamentos, refinanciamentos, aportes e outros aspectos estratégicos, operacionais e financeiros.
- III Opinião com ressalva, opinião adversa e abstenção de opinião sobre as demonstrações contábeis. Necessária quando: (a) o auditor conclui, com base em evidência de auditoria obtida, que as demonstrações contábeis como um todo apresentam distorções relevantes; ou (b) o auditor não consegue obter evidência de auditoria apropriada e suficiente para concluir que as demonstrações contábeis como um todo não apresentam distorções relevantes.
- IV É a opinião expressa pelo auditor quando ele conclui que as demonstrações contábeis são elaboradas, em todos os aspectos relevantes, de acordo com a estrutura de relatório financeiro aplicável.

REFERÊNCIAS

- BISHOP, Christopher M. Pattern Recognition and Machine Learning. Springer, October, 2006. Disponível em <<http://www.rmki.kfki.hu/~banmi/elte/Bishop%20-%20Pattern%20Recognition%20and%20Machine%20Learning.pdf>>. Acessado em: 10 ago. 2015.
- BYRNES, Paul., CRISTE, Tom., TREVOR, Stewart., VASARHELYI, Miklos. Reimagining Auditing in a Wired World. AICPA White Paper, August, 2014. Disponível em: <https://www.aicpa.org/InterestAreas/FRC/AssuranceAdvisoryServices/DownloadableDocuments/Whitepaper_Blue_Sky_Scenario-Pinkbook.pdf>. Acessado em: 11 nov. 2015.
- CALDERON, Thomas G., CHEH, John J. A roadmap for future neural networks research in auditing and risk assessment. International Journal of Accounting Information Systems, Volume 3, Issue 4, December 2002, Pages 203-236. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1467089502000684>>. Acessado em: 18 jan. 2016.
- CERULLO, Michael J., CERULLO, Virginia. Using Neural Network Software as a Foresinc Accounting Tool. Information Systems Control Journal, ISACA, 2006. Disponível em: <https://www.google.com.br/url?sa=t&rc=t=j&q=&esrc=s&source=web&cd=1&cad=rja&uact=8&ved=0ahUKewiGn6W76OvKAhULGpAKHV6UCGQQFggdMAA&url=http%3A%2F%2Fwww.isaca.org%2FJournal%2Farchives%2F2006%2FVolume-2%2FDocuments%2Fpdf0601-using-neural-network.pdf&usq=AFQjCNGLi7Omn2qs3hPy4lqcuxU_AYAmoA>. Acessado em: 15 dez. 2015.
- GARRITY, Edward J., O'DONNELL, Joseph B., SANDERS, Lawrence. Continuous auditing and data mining. Idea Group Inc., 2006. Disponível em: <<http://www.igi-global.com/chapter/continuous-auditing-data-mining/10596?camid=4v1>>. Acessado em: 7 jul. 2015.
- JAIN, Anil K., DUIN, Robert P.W., MAO, Jianchang. Statistical Pattern Recognition: A Review. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 22, nº 1, January, 2000. Disponível em: <http://www.cs.indiana.edu/~predrag/files/jain_2000.pdf>. Acessado em: 22 jul. 2015.
- KOSKIVAARA, Eija. Artificial Neural Networks in Auditing: State of the Art. TUCS Technical Report 509, 2003. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.67.459&rep=rep1&type=pdf>>. Acessado em: 10 out. 2015.
- POURHEYDARI, Omid., NEZAMABADI-POUR, Hossein., AAZAMI, Zeinab. Identifying qualified audit opinions by artificial neural networks. African Journal of Business Management, Vol 6, p. 11077-11087, 7 November, 2012. Disponível em: <http://www.academicjournals.org/app/webroot/article/article1380541005_Pourheydari%20et%20al.pdf>. Acessado em: 2 fev. 2016.
- TAHA, Reem O. Hussein. The possibility of using Artificial Neural Networks in Auditing - Theoretical Analytical Paper. European Journal of Economics, Finance and Administrative Sciences, Issue 47, 2012. Disponível em: <http://www.academia.edu/1634776/The_Possibility_of_using_Artificial_Neural_Networks_in_Auditing_-_Theoretical_Analytical_Paper>. Acessado em: 30 jan. 2016.