

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais



**ESTRATÉGIAS PARA COMBATER A SONEGAÇÃO FISCAL:  
UM MODELO PARA O ICMS BASEADO EM REDES NEURAS ARTIFICIAIS**

**STRATEGIES TO COMBAT TAX EVASION:  
A MODEL FOR ICMS BASED ON ARTIFICIAL NEURAL NETWORKS**

**ESTRATEGIAS PARA COMBATIR LA EVASIÓN FISCAL:  
UN MODELO PARA ICMS BASADO EN REDES NEURALES ARTIFICIALES**

**Francisco Nobre de Oliveira**

<https://orcid.org/0000-0003-4909-4733>

Auditor Fiscal da Secretaria da Fazenda do Estado da Bahia  
Mestre em Ciências Contábeis pela Universidade Federal da Bahia (PPGCont/UFBA)  
E-mail: [fnobre@sefaz.ba.gov.br](mailto:fnobre@sefaz.ba.gov.br)

**Luis Paulo Guimarães dos Santos**

<https://orcid.org/0000-0001-9986-8237>

Professor do Programa de Pós-graduação em Contabilidade (PPGCont/UFBA)  
Doutor em Contabilidade pela Universidade de São Paulo  
E-mail: [lupaufba@gmail.com](mailto:lupaufba@gmail.com)

## RESUMO

A pesquisa teve como objetivo desenvolver um Sistema de Identificação de Risco de Contribuintes baseado em Redes Neurais para auxiliar a Administração Tributária Estadual na identificação de contribuintes mais propensos a assumir a condição de sonegadores do ICMS. Para tanto, foi desenvolvida uma rede neural artificial, denominada Sistema de Identificação de Risco de Contribuintes – SIRC, baseada num modelo *perceptron* de múltiplas camadas, do tipo alimentada adiante (*feedforward*), completamente conectada, composta por duas camadas ocultas e treinada com o algoritmo de retropropagação de erro (*Backpropagation Error*). A construção e operacionalização da SIRC deu-se a partir de informações extraídas dos bancos de dados da Secretaria da Fazenda do Estado da BAHIA (SEFAZ-BA), alimentados por informações prestadas pelos contribuintes, em uma amostra de 74.447 eventos. Na fase de treinamento, a Rede apresentou um índice de acerto de 71% na classificação dos contribuintes passíveis de autuação (ou não). Em relação aos contribuintes que foram autuados, a performance foi de 94%. Estes percentuais atestam a eficácia do modelo como instrumento de apoio a decisões de fiscalização no âmbito da Administração Tributária Estadual.

**Palavras-chave:** Sonegação Fiscal; ICMS; Redes Neurais Artificiais.

---

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

## ABSTRACT

The objective of the research was to develop a Taxpayer Risk Identification System based on Neural Networks to identify taxpayers more likely to assume the status of ICMS tax evaders. In order to achieve this objective, an artificial neural network was developed, called the Taxpayer Risk Identification System (SIRC), based on a multilayer perceptron model of feedforward, fully connected, composed of two hidden layers and trained with the backpropagation error algorithm. The construction and operationalization of the SIRC was done from information available in the databases of the computer systems of the BAHIA State Department of Finance (SEFAZ-BA), fed by information provided by the taxpayers, in a sample of 74,447 events. In the training phase, the network correctly identified 71% of the taxpayers classified as eligible (or not). In relation to the taxpayers who were assessed, the performance was 94%. These percentages attest to the good performance of the system, since the training demonstrated stability in the exit results, considering that in 94% of the cases it was pointed out that the taxpayer is liable to be assessed and in fact is.

**Keywords:** Tax evasion; ICMS tax; Artificial neural networks.

## RESUMEN

La investigación tuvo como objetivo desarrollar un Sistema de Identificación de Riesgos del Contribuyente basado en Redes Neuronales para ayudar a la Administración Tributaria del Estado a identificar a los contribuyentes más propensos a asumir el estado de evasores de impuestos ICMS. Con este fin, se desarrolló una red neuronal artificial llamada Sistema de Identificación de Riesgos del Contribuyente (SIRC), basada en un modelo de perceptrón múltiples capas del tipo alimentada adelante (*feedforward*), avanzado y compuesto por dos capas ocultas y entrenado con el algoritmo de propagación hacia atrás de error (*Backpropagation Error*). La construcción y el funcionamiento del SIRC se basó en información extraída de las bases de datos de la Secretaría de Finanzas del Estado de Bahía (SEFAZ-BA), alimentada por información proporcionada por los contribuyentes, en una muestra de 74,447 eventos. En la fase de capacitación, la Red presentó una tasa de éxito del 71% en la clasificación de los contribuyentes pasables de evaluación (o no). Con respecto a los contribuyentes que fueron evaluados, el rendimiento fue del 94%. Estos porcentajes dan fe de la efectividad del modelo como instrumento para apoyar las decisiones de supervisión dentro de la Administración Tributaria del Estado.

**Palabras clave:** Evasión Fiscal; Impuestos; Redes Neuronales Artificiales.

## 1 INTRODUÇÃO

A sonegação fiscal representa um grande desafio para os governos ao redor do mundo. Buehn e Schneider (2016) documentaram que entre os 38 países membros da OCDE, no período de 1999 a 2010, a taxa média de evasão fiscal girava em torno de 3,2%. Um estudo do Instituto Brasileiro de Planejamento Tributário de 2018 mostrou que os tributos sonegados pelas empresas brasileiras giram em torno de R\$ 390 bilhões por ano e que o montante dos autos de infração emitidos representa 4,6% do PIB brasileiro. Ainda segundo aquele instituto, o ICMS é o tributo mais sonegado.

A sonegação fiscal é um fenômeno complexo tendo em vista os vários fatores que podem interferir na forma como o contribuinte cumpre suas obrigações tributárias, que vão

---

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

desde questões demográfica e econômicas até comportamentais (ver Jackson e Milliron, 1986 e Richardson & Sawyer, 2001, para uma ampla revisão sobre este tema). Riahi-Belkaiou (2004) encontrou evidências de que a sonegação fiscal está negativamente associada com o nível de liberdade econômica, o nível de importância do mercado acionário, a eficácia das leis de concorrência e as normas morais de um país. Além disso, Richardson (2006) documentou que quanto menor o nível de complexidade do sistema tributário e maior o nível de educação geral, fonte de renda de serviços, justiça e moral fiscal, menor será o nível de evasão fiscal de um país.

A evasão fiscal tem impacto no investimento privado e nos gastos do governo, que por seu turno são determinantes da taxa de crescimento econômico e da volatilidade do PIB per capita (Célimène *et al.*, 2016). O sistema deficiente de arrecadação de impostos limita a capacidade de os governos fornecerem a quantidade mínima de bens e serviços públicos necessários para atividades produtivas como infraestrutura, educação ou investimento, provocando, em muitos casos, a estagnação e fortes oscilações no crescimento econômico (Friedman *et al.*, 2000). Por isso, o desenvolvimento de formas de combater a fraude fiscal é uma agenda premente para governos e instituições em todo o mundo.

Do ponto de vista do agente estatal, o conhecimento exato do cumprimento das obrigações tributárias por parte dos contribuintes e seus níveis de evasão devem estar no centro de toda e qualquer ação que vise ao combate à fraude fiscal. A decisão de quais contribuintes devem ser priorizados no momento de se planejarem as ações fiscais é uma questão central no combate à sonegação fiscal. Por conseguinte, os estudos sobre o perfil dos contribuintes têm sido importantes para que governos e instituições entendam o comportamento desses contribuintes.

Neste sentido, alguns estudos têm tentado desenvolver modelos capazes de identificar contribuintes com maior probabilidade de cometer crime de sonegação fiscal. Por exemplo, Sisnando (2000) utilizou uma rede neural do tipo *Multilayer Perceptron* (MLP) para previsão e avaliação de desempenho dos contribuintes do ICMS do Estado do Ceará. Seu estudo concluiu que o modelo de rede neural possibilita resultado bastante superior àquele oriundo do modelo então em uso. Souza (2002), utilizou um tipo de rede neural artificial com topologia de agrupamento conhecida como Mapas Auto-Organizáveis de Kohonen (Self Organizing Map –SOM), que permite a identificação de padrões em vetores de dados, treinado com os dados da Declaração Periódica de Informações (DPI) da Secretaria da Fazenda do Estado de Goiás (SEFAZ-GO). O modelo contribuiu para classificar as empresas com provável sonegação do Imposto sobre Circulação de Mercadorias e Serviços (ICMS). Seu estudo demonstrou a aplicabilidade das RNAs em problemas de ordem prática e os resultados alcançados em seu trabalho comprovam a eficácia da utilização do SOM na classificação de padrões, para o caso de empresas com provável sonegação do ICMS.

Visintín e Baulies (2002) utilizaram um Sistema Automático de Seleção, no âmbito da fiscalização aduaneira da Argentina, sugerindo o cruzamento de informações prestadas pelos contribuintes com outros dados constantes da Administração Federal de Ingressos Públicos (AFIP) da Argentina, com resultados positivos na detecção de risco. Finalmente, Barreto (2005) desenvolveu um novo método de classificação de contribuintes pessoas jurídicas no âmbito da Receita Federal do Brasil (RFB) com base na previsão de seus comportamentos tributários utilizando um classificador operacionalizado por meio de Modelos Lineares Generalizados Hierárquicos (MLGH). Seu estudo concluiu que o novo método de

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

classificação logrou obter valor preditivo positivo superior ao método até então em uso pela RFB.

Estes estudos mostram viabilidade de utilização de ferramentas não convencionais no combate e prevenção de fraudes e evasão fiscal que permite maior eficiência na ação de fiscalização e diminuição nos crimes fiscais. No entanto, conforme alerta Höglund (2017), por causa do significado econômico da sonegação fiscal, relativamente pouca pesquisa tem sido feita na busca de construção de modelos de previsão de risco fiscal. O produto dessas pesquisas importa porque podem ser utilizadas pelas autoridades fiscais para selecionar empresas para auditorias fiscais.

Nesse sentido, o objetivo principal desta pesquisa é desenvolver um Sistema de Identificação de Risco de Contribuintes baseado com a utilização de Redes Neurais, que possa ser utilizado pelas administrações tributárias estaduais para identificar contribuintes mais propensos a assumir a condição de sonegadores do ICMS, tendo em vista que este se trata do imposto mais sonegado no Brasil.

Para a consecução dos objetivos desta pesquisa, foi desenvolvida uma rede neural artificial, denominada Sistema de Identificação de Risco de Contribuintes – SIRC, baseada num modelo perceptron de múltiplas camadas, do tipo alimentada adiante (*feedforward*), completamente conectada, composta por duas camadas ocultas e treinada com o algoritmo de retropropagação de erro (*Backpropagation Error*). A construção e operacionalização da SIRC foi feita a partir de informações disponíveis nos bancos de dados dos sistemas computacionais da Secretaria da Fazenda do Estado da BAHIA (SEFAZ-BA), alimentados por informações prestadas pelos contribuintes, em uma amostra de com 74.447 eventos.

Na fase de treinamento, a rede identificou 71% de forma acertada os contribuintes classificados como passíveis de autuação (ou não). Em relação aos contribuintes que foram autuados, a performance foi 94% e entre os não autuados de 18%. Entre os falsos positivos, ou seja, aqueles que a rede considera o perfil como autuado, o desempenho foi de 93%. Estes percentuais atestam a boa performance da rede, pois o treinamento demonstrou estabilidade nos resultados de saída, isto é, em 94% dos casos ela aponta que o contribuinte é passível de autuação e de fato o é. Este treinamento a que a rede foi submetida mostrou com altos percentuais de aproveitamento, indicando que ela aprendeu a identificar com relativo grau de certeza contribuintes com perfil passível de autuação.

## 2 LITERATURA RELACIONADA

### 2.1 EVASÃO FISCAL

Estudos destinados a identificar os determinantes da evasão fiscal e apontar mecanismos para combater e prevenir esse fenômeno têm se multiplicado em economias emergentes e desenvolvidas. Isto porque além de comprometer a regularidade do fluxo de recursos destinados ao erário, a evasão fiscal acaba prejudicando o funcionamento do sistema econômico na medida em que altera as forças da concorrência e distorce os preços relativos (KHLIF; ACHEK, 2015).

De acordo com Abdixhiku *et al.* (2017), embora a evasão fiscal seja uma questão de grande importância para os governos, suas causas ainda não foram suficientemente investigadas e, conseqüentemente, novos recursos inibitórios precisam ser desenvolvidos. Nesse estudo, eles constaram que a carga tributária percebida tem um impacto positivo na

---

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

evasão fiscal. Observou-se também que o comportamento evasivo das empresas é influenciado positivamente pela baixa confiança no governo e no sistema judicial, bem como pela corrupção e pelos elevados custos de conformidade.

A relação entre comportamentos de evasão fiscal e confiança nas autoridades governamentais também foi observada em estudos realizados por Batrancea *et al.* (2019). Examinando dados coletados em 44 países de cinco continentes, verificou-se que elementos como credibilidade governamental e eficácia de instrumentos coercitivos contribuem para inibir comportamentos de sonegação tributária. Em contraste com estudos anteriores, os resultados sugerem que confiança e poder não são totalmente complementares. Apesar de algumas variações entre países, a confiança e o poder são identificados como importantes determinantes da conformidade tributária em todas as nações. Essas descobertas têm implicações claras para autoridades de todo o mundo que precisam escolher as melhores práticas para cobrança de impostos.

Dion *et al.* (2016) também examinaram os principais determinantes da evasão fiscal e, baseando-se em dados coletados em 45 países, chegaram à conclusão de que fatores de natureza não econômica têm maior influência no comportamento dos contribuintes. Particularmente, observou-se que a complexidade dos mecanismos de tributação é o fator de maior peso para desencadear práticas de sonegação. Ao lado deste, surgem educação, fonte de renda, justiça e moral tributária.

De modo semelhante, Dayday e Zaam (2017) examinaram os principais fatores que levam organizações marroquinas a se engajar em práticas tendentes a reduzir custos tributários. Os resultados sugerem que os fatores mais significativos são: tamanho, volume de transações intragrupo, lucratividade, ativos intangíveis, dívidas e multinacionalidade. Para coibir práticas de sonegação, sugerem-se investimentos em programas de educação tributária e aprimoramento dos mecanismos de fiscalização.

Siqueira e Ramos (2005) demonstram que em termos econômicos, os problemas de sonegação originam-se do fato de que as variáveis que definem a base tributária (rendas, vendas, rendimentos, riqueza, entre outras), não são frequentemente observáveis. Isto é, um ente externo não pode observar o valor real da base tributária de um indivíduo, e daí não pode saber a sua verdadeira responsabilidade tributária, caracterizando a assimetria da informação entre o contribuinte (que sabe a real dimensão de sua renda), e o órgão público. Assim, os contribuintes podem levar vantagem da informação imperfeita que a administração tributária tem sobre sua responsabilidade e procurar iludir a tributação. No entanto, às vezes, esse conhecimento pode ser obtido por meio de auditorias, e, neste caso, diz-se que a base tributária é verificável a um custo que evidentemente não pode suplantar o benefício obtido pelo Estado com a atividade fiscalizadora.

Santos (1997), analisando os aspectos econômicos do fenômeno da evasão fiscal, faz interessante incursão pelo lado comportamental dos contribuintes. Para ele, a evasão e a fraude fiscal, colocam um desafio importante ao economista que é o de encontrar explicações racionais para os comportamentos evasores dos agentes econômicos, em contraponto, ou complemento, das perspectivas normativas. Isto é, a necessidade de construir uma teoria positiva para a evasão e fraude fiscal. Santos (1997), analisa um modelo de evasão em que existem somente variáveis econômicas que determinam a decisão do contribuinte sonegar ou não, mas, ao mesmo tempo, lembra as limitações da proposição de um modelo deste tipo, pois tal modelo ignora outros importantes fatores explicativos do comportamento dos contribuintes

---

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

A teoria evidencia que o contribuinte opta por atender ou não às exigências tributárias tendo em vista ganhos que possa ter caso não venha a ser fiscalizado no período decadencial do tributo. Como a informação sobre a possibilidade de ser fiscalizado (ou não) é assimétrica, pois somente os órgãos fiscalizadores a detém, o contribuinte tende a estabelecer uma relação de custo-benefício dentro de sua função utilidade.

## 2.2 REDES NEURAIAS ARTIFICIAIS

Segundo Pietro *et al.*, (2016), as Redes Neurais Artificiais (RNAs) são construções que tentam simular a estrutura e função do sistema nervoso biológico. Surgiram como uma tentativa de simulação matemática do princípio básico de funcionamento dos componentes mais elementares do sistema nervoso humano. Uma RNA é formada por uma camada de neurônios de entrada (sensorial) e outra de saída (transmissora), podendo ter uma ou mais camadas intermediárias ou ocultas necessárias para a representação de tipos mais complexos de informação.

Wang *et al.* (2020) explicam que as RNAs tradicionais codificam informações neurais pela taxa de pulso (*spikings*) dos neurônios biológicos, na qual as entradas e saídas neurais são geralmente expressas como variáveis analógicas (neurônios com saída binária). Entretanto, segundo os autores, evidências neurocientíficas sugerem que os sistemas nervosos biológicos codificam informações através de pulsos gerados no tempo, fazendo a representação temporal dos pulsos e não apenas da taxa neuronal. Nesse sentido, Barreto (2002) adverte que, embora com inspiração na arquitetura do cérebro humano, as Redes Neurais Artificiais – RNAs atuais estão muito distantes das Redes Neurais Naturais – RNN, sendo as RNAs apenas uma referência a uma simplificação do mecanismo básico de conexão e transmissão das RNNs.

De acordo com Wang *et al.* (2020), as RNAs são modelos computacionais que consistem em neurônios como unidades computacionais básicas e desempenham papéis importantes no processamento de informações e no reconhecimento de padrões. Dependendo de suas unidades computacionais, os modelos de RNA podem ser divididos em três gerações diferentes. Na primeira geração, as RNAs utilizam como unidade computacional os neurônios do tipo McCulloch-Pitts (McCulloch e Pitts, 1943) que têm como principal característica o valor de saída representado como uma variável binária.

Na segunda geração (também conhecida como tradicional), as RNAs usam neurônios artificiais que aplicam funções contínuas como função de ativação dos neurônios para realizar o processamento de entradas e saídas numéricas reais e suportam algoritmos de aprendizado baseados em gradiente. O modelo matemático subjacente à RNAs de segunda geração representa um esquema de codificação de taxa, cujo modelo computacional representativo é a rede neural de retropropagação de *feed-forward* (WANG *et al.*, 2020).

Finalmente, a terceira geração (conhecida como Redes Neurais Pulsadas) utiliza um como unidade básica um modelo de neurônio biologicamente plausível para construção de redes neurais pulsadas mais próximas do neurônio biológico. Esse tipo de RNA faz a representação temporal de pulsos gerado no tempo e pode descrever o sistema nervoso biológico real com mais precisão, de modo a obter um processamento de informações eficiente, especialmente para dados temporais ou espaço-temporais complexos (WANG *et al.*, 2020).

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

A construção de RNAs, inspiradas nos neurônios biológicos e nos sistemas nervosos, teve seu marco inicial com a proposição de McCulloch e Pitts (1943) para um neurônio artificial em que as sinapses eram definidas por pesos atribuídos aos elementos de saída. Este modelo simples tentava imitar a realidade biológica, através de neurônios com saída binária. Conforme pode ser verificado na equação 1, a partir da informação recebida de outros neurônios de entrada em  $x_j$  (sinapses), o processamento consiste em uma combinação linear das entradas traduzido na equação 1.

$$net = w_1x_1 + w_2x_2 + \dots + w_Dx_D = \sum_{j=1}^D w_jx_j = \underline{w}^T \underline{x} \quad (1)$$

A cada entrada está associado um peso  $w_j$  que reflete a importância da entrada  $x_j$ . O resultado desta combinação linear é o valor  $net$ . Se este valor ultrapassar um limiar  $\mu$  o neurônio dispara o valor 1 na saída binária  $y$  e caso não ultrapasse esse limiar a saída fica passiva em  $y = 0$ . A comparação de  $net$  com o limiar  $\mu$  é realizada por uma função de ativação. A função de ativação no caso do modelo de McCulloch e Pitts não é a única maneira de produzir o valor de saída do neurônio artificial. A função linear produz uma saída linear contínua, a função de escada, uma saída binária (não-linear discreta) e a função sigmoideal, uma saída não-linear contínua (RAUBER, 2000). Acrescente-se ainda que a função de ativação pode produzir valores de uma função hiperbólica.

Com a ampliação das pesquisas, as RNAs tornaram-se ferramentas com grande capacidade de generalizar, aproximar funções, reconhecer padrões e classificar conjuntos de dados imprecisos. Estas características resultam em soluções para uma variedade de problemas de classificação tais como reconhecimento de sinais, de caracteres ou de voz, agrupamentos e outros, permitindo uma larga aplicação em diversas áreas do conhecimento. Segundo Luna Huamaní (2003) as redes neurais são uma alternativa para a solução de problemas de identificação e controle envolvendo não linearidades nas dinâmicas inerentes aos sistemas.

A partir do trabalho inicial de McCulloch e Pitts (1943), seguiram-se vários outros estudos, sendo que as atividades nessa linha de pesquisa culminaram em 1957 com a criação de uma rede neural por Frank Rosenblatt, denominada *Perceptron*, que simulava computacionalmente a retina, demonstrando que o sistema nervoso visual reconhece padrões. Porém Marvin Minsky e Seymour Papert (1969) provaram que redes neurais de uma única camada, como a proposta por Rosenblatt, não são capazes, por exemplo, de resolver problemas simples como a operação lógica XOR (OU Exclusivo).

Com relação à sua topologia, uma rede neural em camadas é composta basicamente por uma camada de entrada e uma camada de saída (WANG et al, 2020; PIETRO et al, 2016; HAYKIN, 2001). A função da primeira é transmitir os estímulos do ambiente – ou seja, os sinais de entrada – para os neurônios da camada seguinte, não executando, portanto, nenhum tipo de processamento. Já a função da chamada camada de saída é processar os sinais transmitidos pela camada anterior e apresentar a resposta da rede.

Em alguns casos, as redes podem conter uma ou mais camadas intermediárias entre a camada de entrada e a camada de saída, conhecidas também como camadas ocultas ou camadas de neurônios ocultos, que agem como detectores de características (WANG et al., 2020; PIETRO et al., 2016; HAYKIN, 2001; BRAGA et al., 2007).

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

Na maior parte dos modelos de RNAs, com exceção da camada de entrada, as camadas são constituídas de nodos, unidades de processamento cujo funcionamento baseia-se nos princípios biofísicos dos neurônios biológicos (sinapses). Cada nodo possui terminais de entradas, que recebem os sinais transmitidos e, para cada conexão associada a estes terminais, existe um valor chamado peso, o qual representa a intensidade de sua respectiva força sináptica.

É através da função de ativação, também chamada de função restritiva (Haykin, 2001), que a saída do nodo é calculada. Existem diversos tipos de funções de ativação, como algumas vistas nas Figuras 03 e 04, e o seu uso está associado ao tipo de problema a ser tratado, sobretudo quanto ao tipo e ao intervalo de saída que o nodo deve produzir. A saída de um nodo pode ser transmitida para outros nodos, como uma de suas entradas, ou, caso o nodo esteja na camada de saída, será uma das saídas da rede.

Conforme descrito pela equação 2, para obter a saída de um dado nodo  $k$ , representada na equação por  $y_k$ , toma-se como argumento da função de ativação o somatório do produto entre os sinais de entrada e o respectivo peso associado, também chamado de *campo local induzido* do nodo, (HAYKIN, 2001), representado na equação 3 por  $v_k$ , onde  $N$  é o seu número total de entradas,  $x$  é um vetor que contém os valores de entrada, e seus respectivos pesos estão no vetor  $w$ .

$$y_k = \varphi(v_k) \quad (2)$$

$$v_k = \sum_{i=1}^N x_i w_i + b_k \quad (3)$$

O campo local induzido pode ser acrescido de um valor proveniente do *bias*, um parâmetro externo opcional, representado na equação 1.2 por  $b$ . O bias é o peso da conexão do nodo com uma unidade de processamento fictícia que tem sua saída sempre igual a 1 (FREEMAN e SKAPURA, 1991).

Para realizar tarefas como, por exemplo, o reconhecimento de padrões ou classificação, a RNA treinada mapeia o espaço  $n$ -dimensional, onde  $n$  é número de entradas da rede – em regiões que representam cada uma delas uma classe diferente. De acordo com a localização, em uma das regiões, dos valores da entrada a ser processada é que a rede é capaz de associá-la, quando possível, reconhecendo-a como similar às características de uma das classes. As *fronteiras de decisão* separam as regiões que representam cada uma das classes (FREEMAN e SKAPURA, 1991).

Quanto ao mapeamento que a rede faz, pode-se classificar o problema tratado como linearmente separável ou não linearmente separável. Os problemas linearmente separáveis são aqueles em que as classes estão suficientemente afastadas para que possam ser separadas por uma reta (ou um hiperplano, se o espaço tiver mais do que duas dimensões) e envolvem apenas duas classes (HAYKIN e ENGEL, 2001; BRAGA *et al.*, 2007). Já os problemas não linearmente separáveis possuem fronteiras de decisão mais complexas que podem estar próximas demais para serem separadas por um hiperplano; as classes podem não estar separadas em lados opostos em relação à fronteira de decisão, como é o caso, por exemplo, da representação do OU Exclusivo (XOR).

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

A arquitetura de uma rede neural é determinada por alguns critérios como o número de camadas, quantidade de neurônios em cada camada, topologia, função de ativação, tipo de conexão e de conectividade, e, sobretudo, pelo tipo de aprendizagem adequado ao tratamento do problema. Para que a saída da rede se aproxime do valor desejado, minimiza-se a *função de custo* ou *índice de desempenho* representada na equação 4 por  $\varepsilon$ , onde  $e$  é o sinal de erro obtido e  $n$  é a quantidade de neurônios na camada de saída. De acordo com sinal de erro encontrado, é calculada a variação que os pesos sinápticos devem sofrer, e esse valor é então somado ao valor atual do peso.

Esta variação é obtida através da equação 5, conhecida como *regra delta* ou *regra de Widrow-Hoff* em homenagem à seus criadores (HAYKIN, 2001) onde  $\Delta w_{jk}$  é a variação que será aplicada ao peso  $w_{jk}$ , peso sináptico entre o sinal de entrada e o terminal  $j$  do neurônio  $k$ ,  $\eta$  é um parâmetro chamado de *taxa de aprendizagem*, que é a constante que determina o grau de variação do peso de cada iteração,  $e_k(t)$  é o sinal de erro do neurônio  $k$  no instante  $t$  e  $x_j$  o sinal de entrada no terminal  $j$ . Esse processo iterativo de ajustes é conhecido como algoritmo do *mínimo quadrado médio* (LMS, *least mean square*).

$$\varepsilon(t) = \sum_{i=1}^N e_i^2(t) \quad (4)$$

$$\Delta w_{jk} = \eta \cdot e_k(t) \cdot x_j(t) \quad (5)$$

Denomina-se *época*, cada conjunto de iterações representadas individualmente na equação 6 como instante  $t$  (quando um exemplo é apresentado à rede). A cada *época* é feita apresentação de todos os pares de entrada, com suas respectivas saídas desejadas (HAYKIN, 2001). Dependendo do modo de processamento adotado, seqüencial ou *por lote*, o ajuste dos pesos e parâmetros livres é feito após a apresentação de cada exemplo (seqüencial) ou após a apresentação de todo o conjunto (por lote). Segundo Haykin (2001), esse processo iterativo de mostrar exemplos e de fazer ajustes de pesos e parâmetros livres é o que se chama de treinamento ou aprendizado da rede, que é a forma pela qual a rede adquire conhecimento.

O tipo de aprendizagem utilizado pela rede desenvolvida para este trabalho é conhecida como *aprendizagem por correção de erro*, que consiste em minimizar o sinal de erro encontrado, o qual é obtido pela diferença entre a resposta desejada e a saída atual de um neurônio  $k$ .

O sinal de erro é descrito na equação 6 como  $e_k(t)$ , onde  $t$  é um dado instante de tempo,  $d_k(t)$  é a resposta desejada e  $y_k$  é a saída encontrada.

$$e_k(t) = d_k(t) - y_k(t) \quad (6)$$

Essa fase de aprendizagem é encerrada quando, após um número de épocas, a rede encontra a condição estipulada pelo seu *critério de parada*, que é o método utilizado para determinar quando a rede deve parar de ser treinada (BRAGA *et al.*, 2007).

Existem diversos critérios de parada e cada um possui suas vantagens e desvantagens. Pode-se utilizar não apenas um, mas uma combinação de critérios para tornar mais propícia a convergência da rede para uma solução. Dentre os critérios de parada, destacam-se: (1) o encerramento do treinamento quando a norma euclidiana do vetor gradiente da superfície de erro em relação aos pesos atingir um dado valor que seja *suficientemente pequeno* (HAYKIN,

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

2001); (2) encerrar o treinamento quando o erro médio quadrado da saída da rede *ficar abaixo de uma constante  $\alpha$*  (Braga *et al.*, 2007); (3) quando a sua taxa de variação por época for suficientemente pequena (HAYKIN, 2001); e, (4) periodicamente, após uma quantidade de épocas, interromper o treinamento, testar se a taxa de classificações corretas para os dados do *conjunto de validação* é aceitável e treinar até que essa condição seja satisfeita (HAYKIN, 2001).

Quando existem camadas ocultas na rede, como é o caso da RNA utilizada neste trabalho com a finalidade de classificação de contribuinte como possível sonegador ou não, a correção dos pesos é feita através de *generalização da regra delta* para redes de múltiplas camadas, uma vez que o sinal de erro dos neurônios nas camadas intermediárias não é obtido diretamente pela saída da rede, sendo que a participação destes nodos no erro da camada de saída deve ser calculada para que seus pesos possam ser ajustados corretamente.

O equacionamento do ajuste aplicado aos neurônios ocultos de acordo com a sua parcela de responsabilidade no sinal de erro é conhecido como problema de *atribuição de crédito* e é resolvido pelo algoritmo de aprendizado mais popular e amplamente utilizado, conhecido como *backpropagation* ou retropropagação de erro (HAYKIN, 2001).

### 2.2.1 Utilização das Redes Neurais no Âmbito da Fiscalização Tributária

A literatura tem mostrado ao longo do tempo estudos que apresentam propostas de modelagens utilizando RNAs no combate à sonegação fiscal. Por exemplo, Pérez *et al.* (2019) desenvolveram e testaram uma RNA perceptron multicamadas voltada para a detecção de fraudes na declaração de imposto de renda de pessoas físicas na Espanha. O modelo proposto trabalhou com uma camada oculta e uma camada de saída com função de ativação tangente hiperbólica e Softmax, respectivamente. De acordo com os autores, os resultados encontrados mostraram que o modelo apresentou uma taxa final de eficiência de 84,3% na detecção de fraudes fiscais. Na fase de aprendizado (treinamento) a eficiência foi de 70%. A camada oculta apresentou uma porcentagem de previsão de apenas 15,8% para previsões incorretas tanto na fase de treinamento quanto na fase de teste. Pérez *et al.* (2019) alegam que a modelagem proposta pode ser generalizada para quantificar a propensão de um indivíduo cometer fraudes com relação a outros tipos de impostos.

Rahimikia *et al.* (2017) apresentaram um sistema híbrido inteligente para detectar as ações de sonegação fiscal por parte das empresas no Iran. O sistema desenvolvido e testado pelos autores utilizou RNA perceptron multicamada, máquina de vetor de suporte e a regressão logística (LR) combinados com um algoritmo de otimização de busca harmônica. Segundo os autores, o modelo híbrido foi desenvolvido e testado com dados de declarações fiscais de empresas de diferentes setores econômicos que operam no Irã. Rahimikia *et al.* (2017) documentaram que, no geral, a rede neural perceptron mostrou melhores resultados em comparação aos demais modelos (máquina de vetor e regressão logística.), apresentado eficiência entre 82,26% e 90,34%.

Por sua vez, González e Velásquez (2013), desenvolveram modelos de redes neurais perceptron multicamadas e bayesianas para detectar contribuintes que cometem fraudes na declaração de Imposto Sobre Valor Agregado no Chile. Na rede perceptron o número de camadas e de interações foram definidos por meio do método de tentativa e erros envolvendo a utilização de diversos números. No caso das redes bayesianas, foram utilizados o algoritmo TAN o algoritmo de Estimativa Markov Blanket estimation algorithm disponível no software

---

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

SPSS Clementine. Os autores relatam que a rede neural perceptron apresentou os melhores resultados na detecção de casos de fraudes, chegando a uma taxa de eficiência de 92,6%.

Sisnando e Freitas (2006) realizaram uma pesquisa com o objetivo de oferecer uma proposta alternativa de avaliação do desempenho dos contribuintes do ICMS do Estado do Ceará, utilizando as redes neurais artificiais (RNA), capaz de fornecer previsões mais confiáveis que aquelas apresentadas pelo modelo estatístico em uso até então pela Secretaria da Fazenda do Estado do Ceará (SEFAZ-CE). Conforme indicam os autores, o modelo de avaliação/previsão do desempenho dos contribuintes do ICMS do Estado do Ceará efetua todas as operações e cálculos necessários, fornecendo índices individuais de cada contribuinte e índices médios do segmento de atividade econômica em que ele está inserido, em um mesmo exercício fiscal. A partir daí, demonstram que o modelo gera uma previsão, denominada *Projeção Bruta*, dos valores representativos da base de cálculo da provável sonegação. O principal índice que norteia toda a previsão é denominado *Taxa de Adicionamento* (TA), que é conseguida pela razão entre a saída global (representativa dos valores das saídas de mercadorias declaradas pelo contribuinte ao longo do ano) e a entrada global (representativa dos valores das entradas de mercadorias declaradas pelo contribuinte ao longo do ano). Na conclusão do trabalho é apresentada uma comparação entre o modelo então em uso na seleção de contribuintes para fiscalização e o modelo proposto, baseado em redes neurais, sendo que, de acordo com os autores, o modelo de rede neural apresentou resultado bastante superior àquele oriundo do modelo vigente.

Utilizando dados da Secretaria de Estado da Fazenda de Minas Gerais Paula Júnior *et al.* (2004), desenvolveram e testaram uma RNA multicamadas com função de ativação do tipo tangente bipolar destinada à qualificação e quantificação da sonegação fiscal de ICMS. Os autores utilizaram rede neural perceptron do tipo *feed-forward*, treinada com o algoritmo de retropropagação de erros. De acordo com os autores, os testes executados após o treinamento da rede produziram resultados que classificam as empresas, de acordo com seu grau de sonegação fiscal, com exatidão que vai de 97,8% a 100% de acerto.

### 3 DEFINIÇÃO DO MODELO

#### 3.1 DESCRIÇÃO DA REDE NEURAL ARTIFICIAL UTILIZADA NESTE TRABALHO

A utilização de RNA neste trabalho será melhor compreendida se, analisando a topologia de uma rede neural genérica onde:

- a camada de entrada está representada pelas informações disponíveis nos diversos bancos de dados da SEFAZ-BA a serem utilizadas na seleção de contribuintes (variáveis);
- a camada oculta é onde estão dispostos os neurônios escondidos; e
- a terceira camada é onde são dispostos os neurônios cuja saída é o resultado da avaliação do contribuinte.

Denominamos Sistema de Identificação de Risco do Contribuinte – SIRC, a rede neural artificial utilizada para a consecução dos objetivos deste trabalho, uma rede neural de modelo perceptron de múltiplas camadas, do tipo alimentada adiante (*feedforward*), completamente conectada, composta por duas camadas ocultas e treinada com o algoritmo de retropropagação de erro (*Backpropagation Error*).

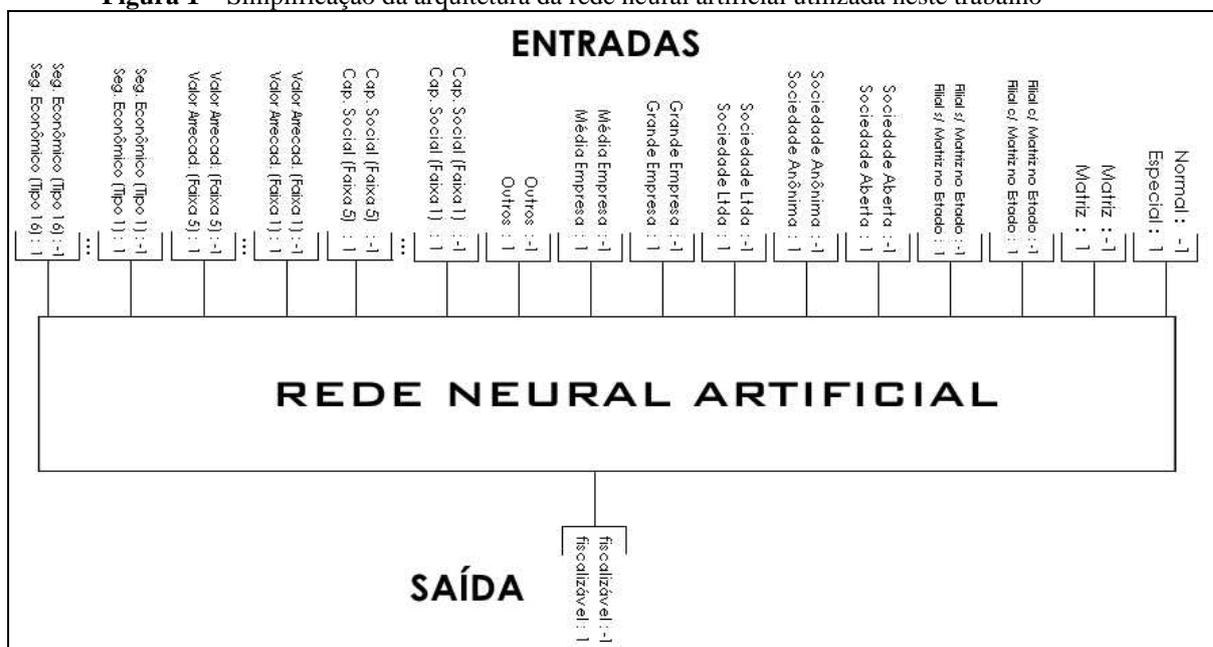
Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

A função de ativação utilizada em todos os nodos da rede é a função tangente hiperbólica de forma que as saídas dos neurônios da rede estão sempre no intervalo entre  $-1$  e  $1$ . Assim, as saídas esperadas para cada uma das classes de contribuintes que podem ser reconhecidas pela rede neural são diametralmente opostas.

O sinal de entrada da rede é composto de 36 campos numéricos, cada um deles associado a uma característica que compõe o perfil de um dado contribuinte. Os valores desses campos sempre serão iguais a  $-1$  (quando a característica **não for** pertinente ao perfil do contribuinte) ou iguais a  $1$  (quando a característica **for** pertinente ao perfil do contribuinte), conforme ilustrado na Figura 01.

Cada um desses perfis possui um rótulo associado – que é utilizado apenas para o treinamento da rede – que determina com base no histórico de autuação dos contribuintes da SEFAZ-BA, se o perfil é considerado de risco ou não, assumindo respectivamente os valores  $+1$  ou  $-1$ . Esse rótulo é a saída desejada que a rede forneça para aquele perfil de contribuinte.

**Figura 1** – Simplificação da arquitetura da rede neural artificial utilizada neste trabalho



Fonte: Elaboração própria

A camada de saída da rede é constituída por apenas um nodo, de forma que, quando o valor desse nodo é positivo (maior ou igual a zero), julga-se que a rede considerou o perfil de contribuinte apresentado como sendo pertencente à uma classe fiscalizável que representa maior risco de fraude. Caso contrário, o perfil do contribuinte é considerado com menor risco de fraude e o valor da saída da rede é negativo.

Essa restrição da saída com base no valor da saída ser negativo ou positivo existe porque nem sempre a saída da rede vai estar nos extremos possíveis do intervalo de saída da função de ativação utilizada, produzindo valores não-lineares no intervalo  $(-1, +1)$ . Os pesos das conexões e bias da rede são inicializados com valores aleatórios entre  $-0.5$  e  $+0.5$  (FREEMAN e SKAPURA, 1991), evitando assim que o algoritmo de retropropagação opere em uma área muito plana em torno da origem da superfície de erro (HAYKIN, 2001).

Além disso, quando a rede converge para um mínimo local, reinicializar os pesos e bias, e treinar a rede novamente pode resolver o problema. O valor da taxa de aprendizagem

---

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

utilizada é 0.15, por ser um valor médio entre o menor e o maior valor da faixa entre 0.05 a 0.25, que é sugerida por James Freeman e David Skapura (FREEMAN e SKAPURA, 1991).

O critério de parada adotado para encerrar o treinamento da rede é uma combinação de critérios, que implica a minimização da norma euclidiana do vetor gradiente da superfície de erro em relação ao vetor de pesos, e a minimização do erro médio obtido até o ponto em que esse valor é superior à média dos erros médios obtidos nas últimas 5, 15 e 25 épocas do treinamento, garantindo assim que o erro atingido foi próximo do menor valor possível para a configuração atual da rede e cuja tendência a partir desse momento para cada nova época é de crescimento.

A minimização da norma euclidiana do vetor gradiente é um critério bastante razoável para garantia de convergência da rede, porém, para assegurar que o treinamento continue até que a rede neural apresente o menor erro possível, é utilizada uma estratégia que compara o valor do erro médio da época atual, com suas médias móveis nas épocas anteriores.

Os períodos de 5, 15 e 25 épocas foram adotados com base no comportamento observado do treinamento da rede, de forma que seja possível verificar não apenas o crescimento ou decréscimo do erro, mas a sua tendência, já que muitas vezes a trajetória do erro obtido possui uma natureza oscilatória. O valor limite para encerramento do treinamento no que diz respeito à norma euclidiana do vetor gradiente é  $10^{-3}$ .

Na rede neural projetada, foram utilizadas duas camadas ocultas uma vez que essa configuração da rede apresentou uma boa convergência e desempenho, além dos melhores percentuais de acerto. O uso de três camadas também foi testado, entretanto, além de acarretar um aumento da dimensionalidade da rede e prejudicar o seu desempenho, tanto no treinamento quanto nos testes, o acréscimo dessa camada não mostrou nenhuma melhora significativa que justificasse tal acréscimo.

A determinação do tamanho das camadas ocultas foi feita de forma experimental, tomando como critério a ideia de usar uma quantidade de nodos suficiente, porém mínima (FREEMAN e SKAPURA, 1991). Dos melhores resultados obtidos pela rede SIRC, mereceram destaque três deles com configurações usando em ambas camadas, 20 neurônios, 30 neurônios e 80 neurônios.

#### 4 TRATAMENTO E ANÁLISE DE DADOS

A construção e operacionalização da SIRC foi feita a partir de informações disponíveis nos bancos de dados dos sistemas computacionais da SEFAZ-BA, alimentados por informações prestadas pelos contribuintes, em uma amostra de com 74.447 eventos. Para cada um destes eventos, obteve-se o rol de variáveis que foram utilizadas como camada de entrada da SIRC.

Os dados utilizados como variáveis que constituem a camada de entrada da rede conforme Figura 5, foram obtidos a partir do Data Warehouse (DW) alimentado a partir dos diversos sistemas relacionais da SEFAZ-BA. Como ferramenta de extração foi utilizado um *Online Analytical Processing (OLAP)* ou Processo Analítico em Tempo Real, de grande aceitação no mercado. Estes dados representam registros históricos de contribuintes do período compreendido entre o ano de 2004 e 2010.

As variáveis que são utilizadas no treinamento da rede neural e que compõem os perfis dos contribuintes, assim como os valores que elas podem assumir, são apresentados na Figura 1, cujo detalhamento de conteúdo está descrito no item 1.5 – Metodologia e Classificação do

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

Estudo. Foram selecionadas variáveis, que representam características dos contribuintes consideradas relevantes por parte dos responsáveis pelas ações de fiscalização e com base na experiência profissional do autor deste trabalho.

Considerando que o objetivo é que a rede estabeleça o potencial de risco de um dado contribuinte ser passível de uma fiscalização mais criteriosa – determinado com base nas variáveis selecionadas – foram realizadas algumas transformações dos dados de entrada fornecidos à rede neural.

Dessa forma a base de dados com 74.447 eventos passa a conter todos os perfis de contribuintes existentes nos dados originais em um nível mais geral e abstrato, sem ater-se a variáveis temporais de cada contribuinte (como, por exemplo, o ano do seu registro nos sistemas relacionais da SEFAZ-BA), ou as variáveis que sejam mais específicas ou particulares de cada contribuinte (como, por exemplo, variáveis de identificação do contribuinte tais como o número da inscrição estadual ou o número do Cadastro Nacional de Pessoa Jurídica CNPJ). O relevante para a interpretação da rede é o perfil do contribuinte.

O perfil dos contribuintes é composto de informações menos específicas, tais como o tipo do contribuinte, porte, segmento econômico ao qual o mesmo pertence, faixa de valor do capital do contribuinte, faixa do valor de arrecadação, entre outros. Assim, a rede neural não recebe como entrada informações específicas de nenhum contribuinte em particular, mas sim diversos perfis que são na verdade todos os possíveis agrupamentos de características mais gerais, que estavam presentes nos 74.447 eventos.

**Quadro 1** – Variáveis utilizadas e respectivos valores possíveis.

Variável	Valores possíveis
Categoria	Matriz
	Filial com matriz no estado
	Filial com matriz fora do estado
Condição	Normal
	Especial
Natureza Jurídica	Sociedade Anônima Aberta
	Sociedade Anônima Fechada
	Sociedade Empresária Limitada
Porte	Grandes Empresas
	Médias Empresas
	Outros
Segmento Econômico	Agricultura
	Agroindústria
	Comércio Atacadista
	Comércio Varejista
	Indústria de Bebidas
	Indústria Metalúrgica
	Indústria de Mineração e Derivados
	Indústria Química
	Indústria de Utilidade Pública
Misto (Indústria)	

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

	Misto (Serviços)
	Petróleo
	Serviços de Transporte
	Serviços de Utilidade Pública
	Supermercados
Capital Social	R\$ 0,00 - R\$ 9.999,99
	R\$ 10.000,00 – R\$ 49.999,99
	R\$ 50.000,00 – R\$ 99.999,99
	R\$ 100.000,00 – R\$ 249.999,99
	Acima de R\$ R\$ 250.000,00
Valor Arrecadado	R\$ 0,00 - R\$ 9.999,99
	R\$ 10.000,00 – R\$ 49.999,99
	R\$ 50.000,00 – R\$ 99.999,99
	R\$ 100.000,00 – R\$ 249.999,99
	Acima de R\$ R\$ 250.000,00

Fonte: Elaborado pelo autor da dissertação

Esse agrupamento é associado a uma variável que representa o risco de um determinado perfil identificado pela rede, ser o perfil de um contribuinte passível de fiscalização mais criteriosa ou não. O risco aqui é estabelecido com base na existência de casos de autuação para o mesmo perfil e que constam daquela massa de registros originais.

Após a realização do treinamento da rede neural artificial, são realizados os testes para cada registro de contribuinte da amostra de 74.447 eventos e a saída obtida pela rede neural é comparada com o potencial de risco que já é conhecido para aquele contribuinte com base no risco associado ao perfil identificado.

#### 4.1 IMPLEMENTAÇÃO DA REDE NEURAL ARTIFICIAL

Para facilitar a importação dos dados, os processamentos necessários para as formatações e transformações da massa de dados do histórico de contribuintes – sobretudo por conta da quantidade de eventos disponíveis que totalizavam 74.447 – foi utilizado o banco de dados Microsoft SQL Server®, embora não haja qualquer restrição ou justificativa imperativa para a escolha dessa ferramenta e toda a operacionalização de dados realizada possa ser feita em qualquer outro banco de dados.

No desenvolvimento do software pelo profissional que implementa a rede neural artificial SIRC, foi adotada a linguagem Java™ da Sun Microsystems®. A opção por esta linguagem e ambiente não foi determinada por nenhum critério de natureza rigorosamente técnica, uma vez que, no contexto deste trabalho, estes elementos são irrelevantes diante do desenvolvimento da aplicação e do foco do trabalho, e não exerceriam nenhuma influência sobre os resultados. Entretanto, a praticidade, os componentes e recursos do ambiente facilitaram a implementação de certas funcionalidades da aplicação, sobretudo no que diz respeito à exploração dos recursos visuais e interfaces gráficas.

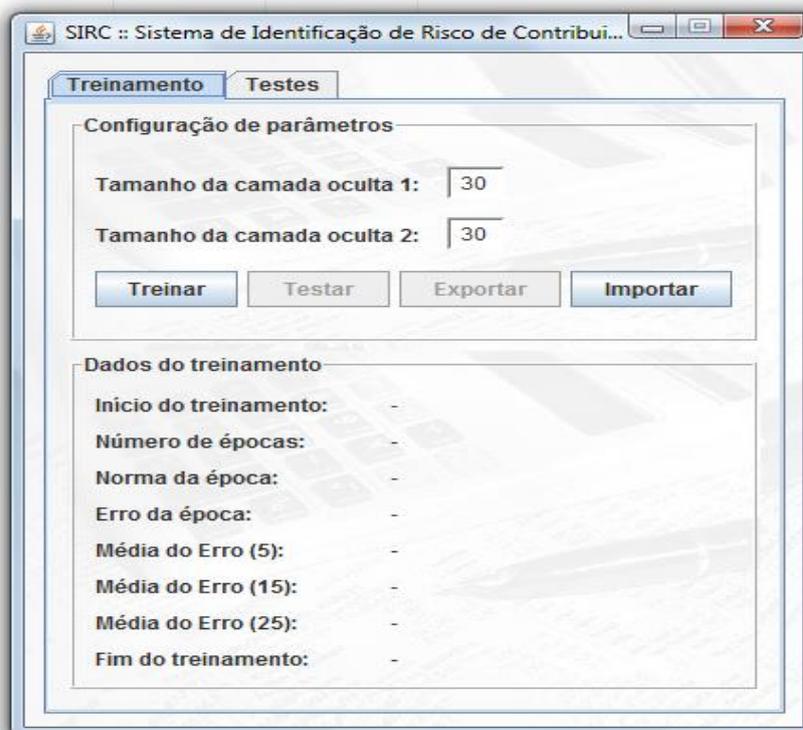
A arquitetura de hardware utilizada para execução do treinamento e testes da rede neural não possui dependência relevante com relação aos resultados obtidos, uma vez que, os procedimentos executados ao longo do treinamento, os quais levam a rede a convergir para uma solução, não possuem nenhuma operação que seja fortemente dependente ou que possa

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

ser significativamente afetada pela arquitetura de hardware a ser utilizada, embora reconheça-se, a medida que o poder de processamento da arquitetura de hardware utilizada aumenta, o tempo requerido tanto para treinamento quanto para testes tende a reduzir significativamente.

A operacionalização da rede neural artificial construída não exige maiores restrições de configuração de hardware para rodar podendo ser instalada em qualquer máquina, pois trata-se de um arquivo executável de pequeno tamanho. A interface gráfica é bastante amigável, como se observa na Figura 02.

**Figura 2** – Interface gráfica da SIRC - Treinamento



Fonte: Tela de apresentação da SIRC, elaborada pelo autor.

A aba Treinamento serve para iniciar o treinamento da rede e verificar o grau de acurácia deste treinamento. Dando-se um *click* na guia Treinar, a rede começa o treinamento com base nos parâmetros estabelecidos pelo usuário para as camadas ocultas, podendo ser diferentes para as camadas 1 e 2.

A aba Testes conforme Figura 3 serve para efetuar os testes aplicáveis a um contribuinte específico, onde são informadas à SIRC, qual o perfil deste contribuinte a partir das variáveis estabelecidas no Quadro 02 e detalhadas no Apêndice. Ao final, a SIRC informará o grau de risco deste contribuinte de acordo com a seguinte classificação, com base nos valores de saída encontrados pela rede:

- Valor de saída entre -1,0000 e 0,0000 => Baixo Risco
- Valor de saída entre 0,0001 e 0,5000 => Risco Moderado
- Valor de entre 0,5001 e + 1,0000 => Alto Risco

Feita a classificação do risco, caberá os usuários indicar o contribuinte para a fiscalização.

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

**Figura 3** – Interface gráfica da SIRC - Testes

SIRC :: Sistema de Identificação de Risco de Contribui...

Treinoamento Testes

Categoria: Filial com Matriz fora do estado

Condição: Normal

Natureza Jurídica: Sociedade Anônima Aberta

Porte Econômico: Grandes Empresas

Segmento Econômico: Agricultura

Capital Social: R\$ 0,00 - R\$ 9.999,99

Valor Arrecadado: R\$ 0,00 - R\$ 9.999,99

Risco: ?

Testar

Fonte: Tela de apresentação da SIRC, elaborada pelo autor.

#### 4.2 RESULTADOS OBTIDOS

Inicialmente, foi realizado um teste aleatório para verificar a acurácia da rede quanto a quatro possíveis categorias, quais sejam:

- Percentual de acertos para os contribuintes considerados autuados, constantes da massa de dados colocada na rede;
- Percentual de acertos para os contribuintes não autuados, constantes da massa de dados colocada na rede;
- Percentual de falsos positivos, ou seja, aqueles contribuintes cujos perfis apresentam similaridades com algum dos perfis dos contribuintes autuados, mas que não possuem histórico de autuações;
- Percentual total de acerto da rede em relação ao total da massa de dados colocada na rede.

Os detalhes deste treinamento são mostrados na Figura 4:

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

**Figura 4** – Tela resumo do treinamento



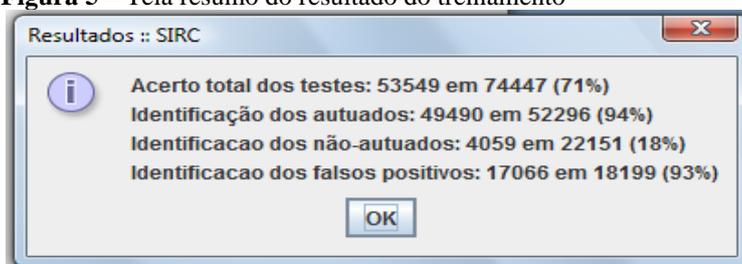
Fonte: Tela de apresentação da SIRC, elaborada pelo autor.

No teste, foi utilizado o mesmo tamanho (30) tanto para a camada oculta 1, quanto para a camada oculta 2. Fica a critério do operador, dependendo da acurácia desejada, definir o tamanho das camadas, conforme salientado no parágrafo que analisou a aba Treinamento

O tempo entre o início e o fim do treinamento (neste caso cerca de 4 minutos) dependerá da performance da máquina utilizada pela SIRC. O número de épocas e dados de erro mostrados neste exemplo evidenciam o critério de parada adotado, que é uma combinação que implica na minimização da norma euclidiana.

A tela abaixo (Figura 5) mostra o percentual total de acerto da rede em relação ao total da massa de dados colocada na rede:

**Figura 5** – Tela resumo do resultado do treinamento



Fonte: Tela de apresentação da SIRC, elaborada pelo autor.

No treinamento a rede identificou 71% de forma acertada no conjunto de testes para os dados a ela apresentados, entre contribuintes que sejam classificados como passíveis de autuação (ou não). Em relação aos contribuintes que foram autuados, a performance é de 94% e entre os não autuados de 18%, enquanto os falsos positivos. Ou seja, aqueles que a rede considera o perfil como autuado é de 93%, uma vez que estes possuem similaridades com algum perfil autuado. Estes percentuais atestam a boa performance da rede, pois o treinamento demonstra

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

estabilidade nos resultados de saída, isto é, em 94% dos casos ela aponta que o contribuinte é passível de autuação e de fato o é. Este treinamento a que a rede foi submetida mostrou com altos percentuais de aproveitamento indicando que ela aprendeu a identificar com relativo grau de certeza contribuintes com perfil de passível de autuação.

A próxima etapa, a partir do aprendizado da SIRC, é aplicar um caso concreto. Isto se faz utilizando a guia Teste, para verificar qual o grau de risco de um determinado contribuinte vir a sonegar ICMS, dado o seu perfil, comparado com aquele que a Rede aprendeu a identificar. Para tanto, a título de exemplificação, considere-se um contribuinte com o seguinte perfil, cujas variáveis estão categorizadas no Quadro 02 e descritas no item 1.5 deste trabalho (Metodologia e Classificação do Estudo):

- É um estabelecimento Matriz;
- A condição é de contribuinte Normal
- Tem como natureza jurídica ser uma Sociedade Empresária Limitada;
- Pertence ao porte de Grandes Empresas;
- Pertence ao segmento de Comércio Varejista;
- O Capital Social está entre R\$.50.000 e R\$.99.999,99;
- A faixa de recolhimento do imposto está entre R\$.50.000,00 e R\$.99.999,99.

Ao ser acionado o botão Testar (Figura 6), a rede compara este perfil com aqueles aprendidos e identifica o grau de risco para a classificação como passível de fiscalização (ou não).

Figura 6 – Simulação de um caso real (1), a partir de dados de um contribuinte

A imagem mostra a interface de usuário do sistema SIRC, especificamente a aba 'Testes'. O formulário contém os seguintes campos e valores:

Campo	Valor
Categoria:	Matriz
Condição:	Normal
Natureza Jurídica:	Sociedade Empresária Limitada
Porte Econômico:	Grandes Empresas
Segmento Econômico:	Comércio Varejista
Capital Social:	R\$ 50.000,00 - R\$ 99.999,99
Valor Arrecadado:	R\$ 50.000,00 - R\$ 99.999,99
Risco:	ALTO (0,85569)

Abaixo dos campos, há um botão 'Testar'.

Fonte: SIRC

A linha RISCO aponta que este perfil tem um risco próximo de **mais** 1 (precisamente 0,85569) e o SIRC o indica como sendo um grau de risco ALTO, portanto merecedor de atenção quando da seleção de contribuintes a serem fiscalizados.

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

Utilizando-se do mesmo treinamento, mas agora apresentando um outro perfil para a rede, a indicação de risco alterar-se-á completamente. Para demonstrar esta afirmativa, utiliza-se agora o seguinte perfil:

- É um estabelecimento Filial com Matriz no Estado
- A condição é de contribuinte Normal, conforme categorizado no Quadro 02
- Tem como natureza jurídica ser uma Sociedade Empresária Limitada
- Pertence ao porte de Grandes Empresas
- Pertence ao segmento da Indústria de Mineração e Derivados
- O Capital Social está entre R\$.10.000 e R\$ 49.999,99
- A faixa de recolhimento do imposto está entre R\$.10.000,00 e R\$ 49.999,99.

A Figura 7 mostra agora que um contribuinte com este perfil apresenta um BAIXO risco de sonegação, dentro dos parâmetros de treinamento oferecidos ao SIRC, pois tem um valor de saída mais próximo de **menos 1** (precisamente -0,59783).

**Figura 7** – Simulação de um caso real (2), a partir de dados de um contribuinte

SIRC :: Sistema de Identificação de Risco de Contribui...

Treinamento Testes

Categoria: Filial com Matriz no estado

Condição: Normal

Natureza Jurídica: Sociedade Empresária Limitada

Porte Econômico: Grandes Empresas

Segmento Econômico: Indústria de Mineração e Derivados

Capital Social: R\$ 10.000,00 - R\$ 49.999,99

Valor Arrecadado: R\$ 10.000,00 - R\$ 49.999,99

Risco: BAIXO (-0,59783)

Testar

Fonte: Elaboração própria

Conclui-se que, apresentados diferentes perfis à rede, diferentes possibilidades de respostas quanto ao risco subjetivo são apresentadas o que pode oferecer uma vantagem em relação aos critérios de seleção feitos atualmente pela SEFAZ-BA. Estes resultados por si só demonstram o quanto a adoção da técnica de Redes Neurais Artificiais pode ser úteis na seleção de contribuintes, centrando o foco naqueles que realmente podem vir a ser passíveis de fiscalização.

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

## 5 CONSIDERAÇÕES FINAIS

A topologia de rede neural utilizada nesta pesquisa permitiu demonstrar que este artefato pode contribuir para uma seleção mais acurada de quais contribuintes estão mais propensos à sonegação e, portanto, devem ser objeto de maior interesse para a fiscalização. Os resultados alcançados mostram que RNAs constituem-se em uma poderosa ferramenta de seleção de contribuintes. A rede construída para o desenvolvimento deste trabalho, denominada Sistema de Identificação de Risco de Contribuinte – SIRC, a partir das variáveis escolhidas, efetuou o treinamento com base em 74.447 eventos e demonstrou que para os casos reais é possível indicar com um bom nível de precisão se um determinado contribuinte tem um Baixo, Moderado ou Alto Risco de vir a sonegar o tributo.

Tratando-se de uma ferramenta com capacidade de identificar e quantificar problemas não linearmente separáveis, esta técnica é útil quando comparada com o procedimento atual da SEFAZ-BA que se baseia pura e simplesmente em cruzamentos de dados dos sistemas relacionais utilizados.

O perfil de contribuintes no Estado da Bahia não é o mesmo dos demais Estados da federação o que pode limitar ou tornar necessária a adaptação da aplicação do modelo aqui desenvolvido a outros entes federativos ou a tributos com características diferentes do ICMS. Este perfil é fortemente influenciado pela base econômica de cada região com vocações diferentes de desenvolvimento e, portanto, sugere-se que estudos sejam feitos levando em conta essa diversidade regional.

## REFERÊNCIAS

ABDIXHIKU, L.; KRASNIQI, B; PUGH, G. Firm-level determinants of tax evasion in transition economies. **Economic Systems** .Volume 41, Issue 3, September 2017, Pages 354-366. <https://doi.org/10.1016/j.ecosys.2016.12.004>

BARRETO, A. S. **Previsão de comportamento e classificação de contribuintes tributários**: uma abordagem por modelos lineares generalizados hierárquicos. 2005. 262 p. Tese (Doutorado em Engenharia da Produção) – Programa de Engenharia da Produção, Universidade Federal de Santa Catarina, Florianópolis, 2005.

BATRANCEA, L. *et al.* Trust and power as determinants of tax compliance across 44 nations, *Journal of Economic Psychology*, v. 74, October, 2019.

BARRETO, J. M. Introdução às Redes Neurais Artificiais. Laboratório de Conexionismo e Ciências Cognitivas UFSC -Departamento de Informática e de Estatística.2002 57 f.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais**: teoria e aplicações. 2. ed. Rio de Janeiro, Editora LTC, 2007.

BUEHN, A.; SCHNEIDER, F. Size and Development of Tax Evasion in 38 OECD Countries: What do we (not) know?. **Journal of Economics and Political Economy**, [S.l.], v. 3, n. 1, p. 1-11, mar. 2016. ISSN 2148-8347. Available at:

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

<<http://www.kspjournals.org/index.php/JEPE/article/view/634>>. Date accessed: 29 May. 2019. doi:<http://dx.doi.org/10.1453/jepe.v3i1.634>.

CÉLIMÈNE, F.; DUFRENOT, G.; MOPHOU, G.; N'GUÉRÉKATA, G. Tax evasion, tax corruption and stochastic growth. **Economic Modelling**. Vol. 52, Part A, 2016, p. 251-258, doi.org/10.1016/j.econmod.2014.10.055.

DAYDAY, A.; ZAAM, H. The Determinants of Tax Avoidance within Corporate Groups: Evidence from Moroccan Groups. **International Journal of Economics, Finance and Management Sciences**. Vol. 5, No. 1, 2017, pp. 57-65. doi: 10.11648/j.ijefm.20170501.15

DION, M. *et al.* The Determinants of Tax Evasion: A Cross-Country Study. **Financial Crimes: Psychological, Technological, and Ethical Issues**, pp 33-57, June, 2016

FREEMAN, J. A.; SKAPURA, D. M. **Neural networks: algorithms, applications, and programming techniques**. Addison-Wesley, Reading, MA, 1991.

FREEMAN, J.A.; SKAPURA, D. M.. **Neural Networks: Algorithms, applications and programming techniques**. Addison-Wesley Publish Company, 1991.

GONZÁLEZ, P. C.; VELÁSQUEZ, J. D. Characterization and detection of taxpayers with false invoices using data mining techniques. **Expert Systems with Applications**. Vol. 40, Issue 5, 2013, p. 1427-1436, doi.org/10.1016/j.eswa.2012.08.051.

HAYKIN, S.; ENGEL, P. M. (Trad.) **Redes neurais: princípios e prática**. 2 ed. Porto Alegre: Bookman, 2001.

HÖGLUND, H. Tax payment default prediction using genetic algorithm-based variable selection. **Expert Systems with Applications**, Vol. 88, 2017, Pages 368-375, doi.org/10.1016/j.eswa.2017.07.027.

JACKSON, B. R.; MILLIRON, V. C. (1986). Tax compliance research: Findings, problems and prospects. **Journal of Accounting Literature**, 5, 125–165, 1986.

KHLIF, H.; ACHEK, I. The determinants of tax evasion: a literature review. **International Journal of Law and Management**, Vol. 57 No. 5, pp. 486-497, 2015. doi.org/10.1108/IJLMA-03-2014-0027

LUDWIG JR., O.; MONTGOMERY, E. **Redes neurais: fundamentos e aplicações com programas em C**. 1. ed. Rio de Janeiro: Ciência Moderna, 2007.

MACHO-STADLER, I.; PEREZ-CASTRILLO, J. D. **Auditing with Signals**. *Economica*. v. 69, p-20. Fev. 2002

McCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, Vol. 5, p. 115-133, 1943.

Estratégias para Combater a Sonegação Fiscal:  
um Modelo para o ICMS Baseado em Redes Neurais Artificiais

- PAULA JUNIOR, G. G.; SILVEIRA, M. R. M.; NETO, F. R. Uma rede neural artificial de múltiplas camadas aplicada ao combate à sonegação fiscal de ICMS. *In: XXXVI – SBPO, Anais*, São João Del-Rei, Minas Gerais, 2004. p. 2030-2041. Disponível em: <http://www.din.uem.br/sbpo/sbpo2004/pdf/arq0032.pdf>. Acesso em 2 de julho de 2020.
- PÉREZ, L. C.; DELGADO R. M.; LUCAS, S. S. Tax Fraud Detection through Neural Networks: An Application Using a Sample of Personal Income Taxpayers. **Future Internet**. 11(4), 86, 2019. doi:10.3390/fi11040086.
- PRIETO, A.; PRIETO, B.; ORTIGOSA, E. M.; ROS, E.; PELAYO, F.; ORTEGA, J.; ROJAS, I. Neural networks: An overview of early research, current frameworks and new challenges. **Neurocomputing**, 214, 242–268. 2016, doi:10.1016/j.neucom.2016.06.014
- RAHIMIKIA, E.; MOHAMMADI, S.; RAHMANI, T.; GHAZANFARI, M. Detecting corporate tax evasion using a hybrid intelligent system: A case study of Iran. **International Journal of Accounting Information Systems**, 25, p. 1–17, 2017, doi:10.1016/j.accinf.2016.12.002.
- RIAHI-BELKAOU, A. Relationship between tax compliance internationally and selected determinants of tax morale. **Journal of International Accounting, Auditing and Taxation**, Vol. 13, 2004. p. 135-143, doi.org/10.1016/j.intaccudtax.2004.09.001.
- RICHARDSON, G. Determinants of tax evasion: A cross-country investigation. **Journal of International Accounting, Auditing and Taxation**, Vol. 15, Issue 2, 2006. p. 150-169, ISSN 1061-9518, doi.org/10.1016/j.intaccudtax.2006.08.005.
- SANTOS, J. C. G. Evasão e fraude fiscais: uma perspectiva económica do fenómeno. **Revista Prospectiva e Planeamento** 2-1996. Colóquio Fraude e Evasões Fiscais. Lisboa. 1997
- SIQUEIRA, M. L.; RAMOS, F. S. A Economia da sonegação: teoria e evidências empíricas. **Revista Economia Contemporânea**. Rio de Janeiro, v. 9, n. 3, p. 555-581. set./dez, 2005.
- SISNANDO, S. R. A.; FREITAS, M. A. de S. Previsão e avaliação do desempenho dos contribuintes do ICMS do estado do Ceará utilizando as redes neurais artificiais. **Revista Econômica do Nordeste**, Fortaleza, v. 37, n. 1, jan-mar. 2006.
- VISINTÍN, V. V.; BAULIES, C. C. **Inteligencia fiscal através de perfis de riesgo integrados para la selección de contribuyentes** p. 1. In: XV CONCURSO MONOGRAFÍAS – CIAT, 2002.
- WANG, X.; LIN, X.; DANG, X. Supervised learning in spiking neural networks: A review of algorithms and evaluations. **Neural Networks**, v. 125, 2020. p. 258-280, doi.org/10.1016/j.neunet.2020.02.011.