



UMA REDE NEURAL ARTIFICIAL DE MÚLTIPLAS CAMADAS APLICADA AO COMBATE À SONEGAÇÃO FISCAL DE ICMS

Geraldo Galdino de Paula Junior

Laboratório de Engenharia de Produção – UENF
Av. Alberto Lamego, 2000 – Campos – RJ 28.013-600
galdino@uenf.br

Marcos Renato Moreira Silveira

Secretaria de Estado da Fazenda
Rua São José, 198 – Centro – Ubá – MG 36.500-000
mrmsilveira@bol.com.br

Raul Fonseca Neto

Departamento de Ciência da Computação – UFJF
Martelos – Juiz de Fora – MG 36.100-000
raulfonsecaneto@ig.com.br

RESUMO

A omissão fiscal de ICMS praticada por empresas é tratada neste trabalho com uma rede neural artificial de múltiplas camadas para auxiliar na classificação, em diferentes graus de possível sonegação, os contribuintes de um ramo específico de atividade econômica, em uma região da Zona da Mata de Minas Gerais. Indicadores setoriais e individuais, baseados em informações fiscais e contábeis das empresas, foram usados para gerar os dados que alimentaram a rede neural. 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. Os experimentos praticados, as análises conduzidas e os resultados alcançados, permitem antever o possível desenvolvimento de outras ferramentas, nas áreas de inteligência artificial e computacional, de maior poder para serem aplicadas no auxílio à auditoria fiscal.

Palavras-chave: redes neurais artificiais, sonegação fiscal, ICMS.

ABSTRACT

The fiscal omission of ICMS practiced by companies is treated in this work with an artificial neural network of multiple layers to aid in the classification, in different degrees of possible withholding, the taxpayers of a specific branch of economical activity, in an area of the Zona da Mata of Minas Gerais. Sectorial and individual indicators, based on fiscal and accounting information of the companies, were used to generate the data that fed the neural network. The tests executed after the training of the neural network, produced results that classify the companies, in agreement with their degree of fiscal withholding, with accuracy ranging from 97,8% to 100% of success. The practiced experiments, the driven analyses and the reached results, allow to foresee the possible development of other tools, in the areas of artificial and computational intelligence, of larger power to be applied in the aid to the fiscal auditing.

Keywords: artificial neural networks, fiscal withholding, ICMS.

1. Introdução

A sonegação de tributos vem merecendo a atenção de setores da sociedade, em especial das classes política e empresarial, de tributaristas e agentes do poder público responsáveis pela administração fiscal.

Os temas que permeiam os debates sobre a questão fiscal incluem a carga tributária elevada e a base reduzida de tributação que sobrecarregam um pequeno universo de contribuintes. A complexidade do sistema tributário e o dismantelamento da máquina fiscal são recorrentes nas discussões em qualquer ambiente em que ocorram. A questão é empolgante e demanda o aprimoramento permanente da legislação fiscal, dos instrumentos de auditoria e de outras práticas fiscais. À Fiscalização cabe aplicar a Lei de Tributos ainda que razões existam como imperativos para seu ajuste e modificação.

Identificar os impostos sonegados, quantificá-los e exercer o poder legal de cobrança são tarefas com as quais a fiscalização deve estar familiarizada. Para tanto, é preciso aplicar medidas eficazes, o que significa estar preparado tecnicamente para adotar procedimentos fiscais idôneos, capazes de detectar com segurança e exatidão o montante do tributo sonegado. Faz-se necessário conhecer os modos de sonegação, o conjunto de medidas técnicas disponíveis e a identificação, dentre elas, das que melhor se aplicam à situação específica de um determinado contribuinte, de tal forma que se possa alcançar resultados mais próximos na qualificação e quantificação dos valores sonegados.

A motivação ligada a este trabalho nasceu da crença de que o conhecimento prévio dos principais meios de sonegação fiscal, aliado à uma aplicação de rede neural que aqui se propõe, são meios eficazes para dar uma indicação clara da provável sonegação fiscal de uma empresa. Além disso, espera-se que essa aliança forneça informações adicionais sobre as formas com que se tenta burlar o fisco.

2. Objetivos

Construir, treinar e testar um sistema neural para utilizá-lo na qualificação e quantificação da sonegação fiscal de ICMS, de empresas inscritas no cadastro da Secretaria de Estado da Fazenda de Minas Gerais, no sistema de recolhimento ‘Débito/Crédito’. A metodologia que resultou deste trabalho, além de aprimorar o combate à sonegação fiscal, é útil em outras situações de auditoria fiscal e contábil. Ela permite ampliar a base de conhecimentos, princípios e idéias sobre como se deve gerenciar e executar a ação fiscal de forma direcionada, concentrada e planejada. Para atingir os objetivos aqui estabelecidos, algumas ações foram conduzidas, como indicado a seguir:

2.1 Ações

- 1) Selecionar contribuintes dentro de determinado universo de empresas e, de posse de indicadores setoriais e índices contábeis, proceder a uma avaliação criteriosa dos mesmos, seguindo as informações geradas por uma rede neural do tipo ‘feed-forward’, treinada com o algoritmo de retropropagação de erros;
- 2) Realizar numa segunda etapa, comparação de índices da empresa com a média obtida a partir de empresas do mesmo setor e porte econômicos;
- 3) Fornecer subsídios para que o fisco, de posse dos índices de classificação da empresa e dos indícios fornecidos pelo sistema, promova fiscalização consistente e eficiente na unidade fiscalizada — por exemplo, a partir da verificação de um determinado tipo de operação fiscal;
- 4) Visualizar o grau de omissão de receita em relação à expectativa de recolhimento do ICMS, de forma individualizada e setorizada, sem desconsiderar outras variáveis como o porte do estabelecimento e sua forma de comercialização;

5) Atuar como instrumento de avaliação da eficiência da ação fiscal, facilitando o processo de gerenciamento do sistema.

3. Objetivos Específicos

1) Analisar quantitativamente a sonegação através da classificação de uma determinada empresa em relação aos padrões de sonegação adotados.

2) Analisar qualitativamente a sonegação através da integração entre o padrão classificatório e o índice de sonegação existente (através do exame de indicadores fiscais e contábeis (NEVES & VICECONTI, 1998)).

4. Desenvolvimento

Os indicadores setoriais foram tratados visando promover uma normalização para adequá-los à entrada da rede neural. A saída desejada da rede é composta de um símbolo (literal), que fornece a classificação da empresa quanto ao grau de possível sonegação por ela praticada, em relação ao setor pesquisado (SILVEIRA, 2001).

Para produzir essa informação utilizou-se uma rede neural do tipo feed-forward, treinada com o algoritmo de retropropagação de erros (RUMELHART, HINTON & WILLIAMS, 1986), (PRINCIPE, EULIANO & LEFEBVRE, 2000), (BISHOP, 2003).

Um passo padrão é apresentado à camada de entrada da rede (as informações para compor esse passo são obtidas da análise contábil de um subconjunto dos índices individuais e setoriais obtidos). A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída. Nesse ponto a saída obtida é comparada à saída desejada para esse padrão em particular. Se esta não estiver correta, o erro é calculado e retropropagado a partir da camada de saída até a camada de entrada. Os pesos das conexões das unidades ocultas vão sendo modificados em conformidade com a retropropagação do erro.

Através dessa ‘calibração de pesos’ a rede torna-se eficiente através de um sistema independente de aprendizado. Com um erro aceito como ‘satisfatório’, a rede passará a ser utilizada como ferramenta para classificação de novos dados, usando, nesse caso, somente o modo progressivo (feed-forward).

O resultado final é a apresentação de uma classificação da empresa em um de diversos níveis de sonegação (A, B, C, D ou E), aliada a informações úteis para o trabalho de auditoria fiscal (índices de ‘caixa dois’, saídas abaixo do custo, saídas não acobertadas de documentação fiscal, etc.)

4.1 Principais Práticas de Sonegação Fiscal

As práticas mais comuns de sonegação de imposto podem ser resumidas nos seguintes itens:

- Venda de mercadorias e prestação de serviços sem a correspondente emissão de documentação fiscal
- Venda de mercadorias e prestação de serviços com emissão de documentos fiscais com valores menores do que os reais
- Entrega de mercadorias a destinatário diverso do constante na documentação fiscal
- Aproveitamento indevido de crédito de ICMS
- Saída de mercadoria e prestação de serviço com os documentos correspondentes emitidos com valores abaixo do custo
- Utilização de fraudes nos documentos fiscais
- Cancelamento irregular de documentos fiscais
- Falta de registro de documentos fiscais de entrada

- Transferência de créditos de imposto sem a remessa de mercadoria ou sem prestação de serviço ou ainda sem autorização expressa
- Manipulação de informações armazenadas em meio magnético
- Erros de cálculos aritméticos
- Interpretação errônea da Legislação

4.2 Indicadores Fiscais

Os indicadores setoriais de natureza fiscal aqui utilizados permitem a análise do comportamento fiscal de um contribuinte específico, de forma individual ou em um contexto setorial.

A abordagem individual faz-se através de documentos fornecidos pela empresa (DAPI, DAMEF), contendo dados fiscais e contábeis, que são analisados e tornam-se fonte imprescindível de instâncias alimentadoras do sistema neural. O DAPI tem periodicidade mensal e o DAMEF, anual.

A abordagem setorial é feita através da comparação entre empresas de um mesmo ‘Código de Atividade Econômica’ (CAE). O controlador possibilita a identificação dos contribuintes que apresentam comportamento destoante do esperado para um determinado setor — tais como a comparação de índices de agregação fiscal, individual e setorial, etc.

Os resultados fornecidos pelo sistema neural são baseados em informações originadas do DAPI ou do DAMEF, com os valores relativos às entradas, saídas, crédito, débito e saldo apresentados em determinado período, conforme o lapso de tempo selecionado para análise (os valores são expressos em reais, com conversão, pelo sistema, para UFIR)

As informações processadas pelo sistema fornecem dados que demonstram as tendências dos comportamentos individuais das empresas do setor. Deve-se considerar um período de análise superior a seis meses, não permitindo assim, a influência dos efeitos sazonais e de variações de estoque.

4.3 Indicadores Fiscais Individuais

As informações de cada empresa lançadas no sistema permitem o estabelecimento de ‘Indicadores Fiscais’ para cada contribuinte do setor previamente selecionado.

A priorização e outros procedimentos indicados pela rede não devem ser considerados como ‘veredicto final’ sobre a empresa objeto de análise, pois existem fatores externos em determinadas circunstâncias que podem conduzir a situações não condizentes com a realidade.

4.3.1 Agregado Fiscal

$$A_f = \frac{S_t}{E_t} \cdot 100, \text{ onde } A_f \text{ é o agregado fiscal, } S_t \text{ a saída tributada, e } E_t \text{ a entrada tributada. É uma}$$

relação entre os ‘valores tributáveis’ de saída e os de entrada, informando quanto o contribuinte tem acrescido (agregado, somado) na base de cálculo de saída em relação à base de cálculo de entrada no período considerado.

4.3.2 Alíquotas Médias de Entradas/Saídas

$\hat{A}_m^E = \frac{V_c}{T_c} \cdot 100$, onde \hat{A}_m^E é a alíquota média de entrada, V_c é o valor do crédito, e T_c é o total de entradas com créditos.

$\hat{A}_m^S = \frac{V_d}{T_d} \cdot 100$, onde \hat{A}_m^S é a alíquota média de saída, V_d é o valor do débito, e T_d é o total de saídas com débitos.

⟨ XXXVI - SBPO ⟩

A análise destes dois indicadores provê informações acerca da origem e destino das mercadorias do contribuinte, facilitando a identificação daquelas empresas com indícios de irregularidades no tocante à aquisição e saída de seus produtos.

4.3.3 Índices de Recolhimento em Relação a Entradas

$I_r = \frac{S_d}{T_c^E} \cdot 100$, onde I_r é o índice de recolhimento em relação a entradas, S_d é o saldo devedor, e T_c^E é o total de entradas com crédito.

Este é o índice mais complexo e sua análise não deve ser feita de forma isolada, uma vez que os valores de imposto a serem recolhidos dependem de outras variáveis, como o agregado fiscal e as alíquotas médias.

4.3.4 Índices de Entrada com Crédito em Relação à Entrada Total

$\frac{E_c}{E_t}$, é a proporção de crédito de ICMS aproveitado no período (E_c), em relação do total de compras efetuadas pela empresa (E_t).

4.3.5 Índice de Saída com Débito em relação à Saída Total

$\frac{S_d}{S_t}$, indica a proporção de crédito de ICMS aproveitado no período (S_d), em relação ao total de vendas efetuadas pela empresa S_t .

4.4 Indicadores Fiscais Setoriais

Nascem de relações estabelecidas entre duas grandezas contábeis, facilitando sensivelmente o trabalho do fiscal, uma vez que a apreciação de certas relações ou percentuais é mais relevante que a observação de montantes em si.

De posse dos dados de apuração do ICMS de determinado período (superior a 6 meses), das empresas de todas as atividades existentes, este indicadores mostram o comportamento do setor como um todo, possibilitando a seleção de um CAE dentro de um determinado setor, com base nos índices obtidos pelo sistema, apurados da mesma forma dos indicadores individuais, correspondendo apenas ao somatório das informações de todas as empresas do setor.

$A_s = \frac{S_t^T}{E_t^T} \cdot 100$, onde A_s é o agregado setorial, S_t^T é a saída tributada CAE, e E_t^T é a entrada tributada total CAE.

$\bar{A}_E = \frac{C_t}{T_c^E} \cdot 100$, é a alíquota média de entrada do setor, C_t é o crédito total CAE, e T_c^E é o total de entradas de créditos CAE.

⟨ XXXVI - SBPO ⟩

$I_r = \frac{S_d^T}{T_e^C} \cdot 100$, onde I_r é o índice de recolhimento em relação à entrada do setor, S_d^T é o saldo devedor Total CAE, e T_e^C é o total de entradas de crédito CAE.

Os indicadores individuais e setoriais são comparados e usados na montagem de um quadro que indica as relações contábeis possíveis de serem aferidas (SILVEIRA, 2001).

4.5 Alíquota de Estoque

Representa o percentual de ICMS em relação ao estoque de mercadorias tributadas. $A_E = \frac{S_c}{E_m^t}$, é a alíquota de estoque, S_c é o saldo credor de ICMS, e E_m^t é o estoque de mercadorias tributadas.

4.6 Índice de Rotação de Estoque de Mercadorias Tributadas

Demonstra quantas vezes o estoque foi renovado durante o exercício.

$R_E = \frac{C_m^V}{(E_i + E_f) / 2}$, onde R_E é a rotação de estoque, C_m^V é o custo da mercadoria vendida, e E_i e E_f são os estoque inicial e final.

4.7 Prazo Médio de Renovação de Estoques

$P_m = \frac{360 \cdot E_m}{C_v}$, onde $E_m = (E_i + E_f) / 2$ é o estoque médio.

Um quadro de relações contábeis formados com esses três últimos indicadores está em (SILVEIRA, 2001).

4.8 A Rede Neural

Perceptrons de múltiplas camadas, treinados de forma supervisionada com o algoritmo de retropropagação de erros, têm sido usados com sucesso para resolver problemas complexos. Seguindo o que sugere essa observação, formulou-se, para esse trabalho, um modelo de rede neural, usando dados fiscais de 528 empresas moveleiras da Zona da Mata/MG. Essas empresas formam um grupo seletivo daquelas conhecidas na linguagem fiscal, como de 'débito/crédito'. São empresas de porte econômico considerável que possuem um tratamento fiscal e contábil que se traduz por 'o imposto incidente na saída das mercadorias é compensado pelo imposto pago na entrada de matéria prima'. Uma análise econômica dessas empresas mostra certa homogeneidade definida pela semelhança em seus diversos índices. Os componentes do grupo econômico formado por essas indústrias tendem a possuir um comportamento fiscal que varia de levemente sonegador ao extremo de 100% sonegador.

4.8.1 Definição das Instâncias e Graus de Sonegação Fiscal

O período considerado para as instâncias foi de 25 meses. O arquivo de entrada para a rede neural foi formado por um elenco de várias instâncias, sendo que cada instância foi formada por seis indicadores

setoriais individuais: (i) agregado fiscal, (ii) alíquota média de entrada, (iii) alíquota média de saída, (iv) índice de recolhimento em relação à entrada, (v) entradas com crédito em relação às entradas totais e (vi) saídas com débito em relação às saídas totais. Esses índices setoriais individuais formam as colunas de alimentação da rede neural e parte deles compõe a tabela 1.

Tabela 1. Indicadores setoriais individuais de 19 das 528 instâncias utilizadas para treinamento e validação da rede neural

Empresa	Agregado	AME	AMS	Irec/ENT	EC/ET	SD/ST	Desejado
1	19,15	12,59	11,48	1,09	85,48	96,60	D
2	38,41	16,19	12,06	0,99	69,43	99,86	C
3	51,20	14,18	11,33	0,00	69,43	90,95	D
4	51,43	12,40	8,17	0,00	83,87	91,49	E
5	-27,36	12,40	8,51	0,00	90,11	91,60	E
6	106,39	13,67	7,98	0,00	93,41	100,00	C
7	23,36	14,49	10,13	0,00	89,43	100,00	D
8	95,00	14,08	11,32	8,00	89,76	99,45	A
9	44,09	12,30	9,77	1,62	96,93	99,85	D
∑	∑	∑	∑	∑	∑	∑	∑
21	59,12	13,81	9,99	0,00	92,97	97,34	D
22	28,49	12,85	10,71	0,00	90,08	90,51	E
23	48,02	12,40	11,34	4,39	89,49	100,00	B
24	20,21	11,56	10,83	1,46	84,53	98,81	D
25	144,92	15,64	9,25	7,01	95,05	100,00	A
26	30,69	13,71	13,80	4,32	92,79	99,98	B
27	57,49	13,51	9,83	1,97	79,87	98,52	C
28	-85,33	12,92	12,00	0,00	96,30	100,00	E
29	92,27	14,82	10,06	0,00	89,29	99,69	B
30	7,86	12,17	12,11	0,89	93,64	100,00	D
∑	∑	∑	∑	∑	∑	∑	∑

Os graus de sonegação permitem situar a empresa dentro do padrão utilizado para a classificação de sonegação fiscal. O quadro 1, a seguir, mostra o padrão de classificação adotado.

Quadro 1. Graus de possível sonegação praticados pelas empresas

Grau de Classificação	Situação da Empresa
A	Ínfima sonegação, comportamento ideal
B	Sonegação média
C	Sonegadora
D	Altamente sonegadora
E	Sonegação próxima a 100%

A partir da especificação das colunas utilizadas como entrada, selecionou-se a coluna que contém os valores desejados. Esta coluna define o ponto de supervisão da rede neural.

A seguir, especificou-se a quantidade (70%) de linhas que serviriam para treinar a rede, para a validação cruzada (20%) e, para teste, (10%). A fase de teste foi executada após exaustivo treinamento e calibração da rede. A conferência de validação cruzada permite que a rede, em seu auto-aprendizado,

possa se certificar de que, efetivamente, a classificação está indo na direção correta. Tal constatação parte do fato de que a rede, a cada número de épocas processadas, confere se o índice de classificação adquirido enquadra-se nos índices de classificação utilizados pelos dados reservados para a validação cruzada.

O próximo passo constituiu-se da construção da rede neural, propriamente dita. Tal construção é, por assim dizer, ‘artesanal’. Obviamente, neste ponto já se havia decidido sobre o modelo ou topologia de rede a ser utilizado. Neste caso, a escolha caiu sobre o Perceptron de múltiplas camadas. Procedeu-se, então a alimentação da rede com as informações da Tabela 1, com vistas ao seu treinamento, validação cruzada e teste.

4.8.2 Composição das Camadas da Rede Neural

1) A é o número de neurônios da camada de entrada (um neurônio para cada indicador setorial), que deve coincidir com o comprimento dos vetores de entrada para o treinamento. C é o número de neurônios da camada de saída. Escolhe-se B como o número de neurônios das camadas intermediárias. As camadas de entrada e intermediárias têm um neurônio adicional usado como bias;

2) Inicializa-se, aleatoriamente, os pesos da rede;

3) Inicializa-se as ativações dos neurônios, com bias;

4) Escolhe-se um par ‘entrada-saída’. Atribui-se níveis de ativação aos neurônios da camada entrada

5) Propaga-se a ativação dos neurônios da camada de entrada para as camadas intermediárias, utilizando-se a função sigmóide unipolar $(h_k) = 1/(1 + e^{-a})$, $k = 1, \dots, B$, $a = \hat{\mathbf{a}}^A_{l=0} w_{lk}^1 u_l$;

6) Propaga-se a ativação dos neurônios da última camada intermediária para os da camada de saída: $y_i = 1/(1 + e^{-a})$, $k = 1, \dots, C$, $a = \hat{\mathbf{a}}^C_{l=0} w_{lk}^2 h_l$;

7) Calcula-se o erro de cada um dos neurônios da camada de saída, denotado por δ_{2k} , sendo $\delta_{2k} = y_k(1 - y_k)(t_k - y_k)$, $k = 1, \dots, C$;

8) Calcula-se o erro de cada um dos neurônios das camadas intermediárias, denotado por δ_{1k} , $\delta_{1k} = h_k(1 - h_k) \hat{\mathbf{a}}^C_{l=1} \delta_{2l} w_{lk}^2$, $k = 0, \dots, C$;

9) Ajusta-se cada um dos pesos entre a camada de entrada e as intermediárias, de acordo com $\Delta_{2lk} = \eta \delta_{2kj} h_l$, $l = 0, \dots, B$, $k = 0, \dots, C$;

10) Volta-se à etapa 4 e repete-se cada um dos passos a partir deste ponto. Quando todos os pares tiverem sido apresentados à rede, uma ‘época’ terá sido completada. Repete-se cada uma das etapas de 4 a 10, para tantas épocas quantas forem desejadas.

5. Resultados

O processamento das informações da rede foi automatizado através do uso do software Neurosolution (<http://www.nd.com>). Com ele foram conduzidos os experimentos aqui descritos.

O processo de treinamento da rede foi conduzido com a adoção dos seguintes parâmetros:

A primeira camada interna da rede foi composta de 12 elementos de processamento; função de ativação do tipo tangente bipolar, passo inicial de 1 e momentum igual a 0,8.

A segunda camada interna foi composta de 6 elementos de processamento; função de ativação do tipo tangente bipolar; passo igual a 0,1 e momentum igual a 0,75.

A camada de saída foi composta de 5 elementos de processamento com a finalidade de indicar o grau de sonogabilidade da empresa pesquisada. Cada elemento de processamento denota uma classificação utilizada (de A a E).

O controle do aprendizado supervisionado definiu as características utilizadas para tal fim. Para esse tipo de aprendizagem, levou-se em consideração a importância dos cálculos requeridos para minimizar o erro, pois dependem do algoritmo utilizado. No uso do algoritmo de retropropagação de erros considerou-se o tempo requerido por iteração e o número de iterações por padrão de entrada para o erro alcançar um valor mínimo durante a sessão de treinamento. Além disso, foi observado se o algoritmo atingia um mínimo local ou global e caso atingisse um mínimo local, a questão se voltava para a possibilidade de se escapar dele.

O algoritmo de retropropagação de erros fornece uma ‘aproximação’ para a trajetória no espaço de pesos calculada pelo método de descida mais íngreme. Quanto menor for o parâmetro da taxa de aprendizado (passo), menor serão as variações dos pesos sinápticos da rede, de uma iteração para a outra; e mais suave será a trajetória no espaço de pesos. Essa melhoria é obtida à custa de uma taxa de aprendizagem lenta. Por outro lado, se o passo de aprendizagem fosse feito muito grande para acelerar a taxa de aprendizagem, as grandes modificações nos pesos sinápticos resultantes poderiam tornar a rede instável (oscilatória). Assim, a inclusão do termo de ‘momentum’ contribuiu para que a rede não sofresse oscilações precoces, além de evitar que o processo de aprendizagem terminasse em um mínimo local.

O controle do método de aprendizagem supervisionado foi feito com o intervalo de épocas igual a 1000, com atualização de peso em lote.

A evolução do processo de treinamento e seu desempenho foram acompanhados com auxílio da matriz de confusão e da matriz de validação cruzada. A matriz de confusão permite visualizar o percentual de acerto de cada padrão de classificação. A convergência da rede é caracterizada a partir do ponto em que os índices percentuais das matrizes de confusão de iterações subseqüentes, ficam similares.

Após o início do treinamento da rede, constatou-se a primeira oscilação em torno de 402 épocas. O erro quadrático médio ficou próximo a 0,2. O padrão de classificação B (sonogação média) atingiu cerca de 98% de acerto. Como opção para que o algoritmo convergisse e eliminasse a oscilação, o passo foi diminuído entre as camadas internas da rede. Tal medida tornou o processo de aprendizado da rede mais lento.

Como primeiro ajuste, reduziu-se o passo do momentum para 0,5 entre a camada de entrada e a primeira camada oculta. O mesmo ajuste foi efetivado em relação ao momentum referente à retropropagação.

O ajuste entre a primeira camada interna e a segunda foi realizado com a redução do passo para 0,05. Os percentuais de transferência foram mantidos.

Foi efetivado o mesmo ajuste no momentum entre as camadas ocultas (passo reduzido para 0,05) .

A calibração do passo referente à segunda camada interna e a camada de saída foi realizada com o valor 0,001.

Após os ajustes realizados a estabilização da rede foi alcançada, embora a convergência tenha se tornado mais lenta.

A segunda oscilação da rede aparece em torno de 1200 épocas. Novamente foram realizados os ajustes finos nos passos entre as camadas: entre a camada de entrada e a primeira camada interna o passo foi reduzido para 0,1. Como antes, procedimento idêntico foi realizado em relação à retropropagação de erros.

Entre as duas camadas internas, o passo foi reduzido para 0,01, com igual ajuste para o termo momentum referente à retropropagação.

Entre a segunda camada interna e a camada de saída, o passo do algoritmo de aprendizagem foi mantido em 0,001, com procedimento similar ao termo momento da retropropagação.

Após os ajustes finos realizados, a rede adquiriu maior estabilidade, embora, como antes, sua convergência tenha se tornado mais lenta. Após 1000 épocas adicionais, a situação observada era a seguinte: o erro quadrático médio estava em torno de 0,1, e o percentual de acerto da classificação em

relação ao padrão D (altamente sonegadora) estava em 94,65% de acerto; em relação ao padrão C, 0%; em relação ao padrão E, 99,04%; em A, 99,16%; e em B com 99,4%. A partir deste ponto a rede começa o aprendizado em relação à classificação do padrão C.

Com 1000 épocas a mais, o erro quadrático médio se situa em torno de 0,079. A rede começa o aprendizado do padrão C. Após 2000 épocas, o aprendizado da rede torna-se mais rápido. Com 4000 épocas adicionais, a rede neural sofre sua terceira oscilação. Os ajustes realizados neste momento foram (com erro quadrático médio na casa dos 0,15): entre a camada de entrada e a primeira camada interna, ajuste do passo a 0,05. Entre as duas camadas internas, diminuiu-se o passo para 0,005 e manteve-se o mesmo tamanho de passo entre a última camada interna e a camada de saída (0,001). Com mais 3000 épocas, depois do ajuste, o erro quadrático médio estava em torno de 0,06%.

Finalmente, com mais 4000 épocas, a rede converge em seu ponto de mínimo global e se estabiliza. O erro quadrático médio ficou em torno de 0,013, ou seja, com um índice de aprendizagem de classificação com erro ínfimo.

O percentual da classificação correta dos diversos padrões de sonegação está demonstrado na tabela 2.

Tabela 2. Percentual de classificação correta dos diversos padrões de sonegação

D	C	E	A	B
99,06%	99,12%	99,04%	99,58%	99,40%

Após a fase de treinamento da rede, chega-se ao teste. Os dados utilizados para tal propósito foram selecionados do conjunto original de instâncias e não foram usados no processo de treinamento.

Após a execução dos testes para constatar a generalização obtida pela rede, bem como produzir a certificação que a mesma não foi ‘super-treinada’, selecionou-se três empresas inscritas no cadastro de contribuintes da Secretaria de Estado da Fazenda de Minas Gerais, com atividade econômica de ‘Fabricação de Móveis de Madeira’, aqui denominadas de empresas 1, 2 e 3.

A empresa 1 faz parte do rol de empresas cujo sistema deveria classificar como de padrão A, ou seja, com percentual de sonegação mínimo. A empresa 2 aproxima-se muito, em termos fiscais, da empresa 1, com a ressalva de que esta empresa tem alguns débitos pendentes com a fiscalização.

Assim, a correta classificação da empresa 2 deveria ser o padrão B. Já a empresa 3 é uma contumaz sonegadora da região. Com mais de 13 autos de infração a ela atribuídos, essa empresa está, inclusive, inscrita em dívida ativa. O padrão da empresa 3 é o E. Após alimentar a rede neural (já treinada) com os indicadores setoriais destas três empresas, obteve-se o resultado constante da matriz de confusão representada pela tabela 3.

Tabela 3. Resultados fornecidos pela matriz de confusão para as três empresas testadas

	E	B	D	A	C
E	100,000000	0,000000	0,000000	0,000000	0,000000
B	0,000000	97,777779	0,000000	2,222222	0,000000
D	0,000000	0,000000	100,000000	0,000000	0,000000
A	0,000000	0,000000	0,000000	100,000000	0,000000
C	0,000000	0,000000	0,000000	0,000000	100,000000

Analisando os dados da tabela 3, que contém as entradas da matriz de confusão, observa-se que a rede classificou corretamente as empresas dentro dos padrões desejados, com a precisão de 100% para os padrões A e E, e 97,78% para o padrão B.

6. Conclusões

Este trabalho procurou construir, treinar e testar uma rede neural artificial para utilizá-la como auxílio na auditoria da sonegação de ICMS praticada por empresas que recebem o tratamento fiscal e contábil pelo sistema de recolhimento ‘Débito/Crédito’. Ou seja, procurou estabelecer uma metodologia para determinar a provável infração fiscal cometida pelas empresas. Os resultados obtidos demonstram que foi alcançada uma metodologia bastante poderosa para aprimorar a eficiência da ação fiscal. É evidente que se chegou a um estágio que demonstra também o quanto é possível ampliar o que se fez para se chegar a uma sofisticação muito maior, possivelmente em termos de um aparato computacional amigável para uso no cotidiano das repartições fiscais. Este esforço permite uma análise que leva à constatação de que não basta à sociedade simplesmente um elenco de leis e normas para definir os contornos de um comportamento fiscal ideal por parte dos contribuintes. É preciso aprimorar a eficiência da ação fiscal através de conhecimentos e instrumentos modernos que já estão disponíveis e que possuem um grau destacado de maturidade. O que se perde a partir da não utilização desses instrumentos modernos de abordagem é um grande volume de recursos que desaparece nas veias da omissão fiscal, ou com a manutenção pelo Estado de uma estrutura burocrática pesada, cada vez maior, para se ocupar dos procedimentos e das ações de fiscalização.

O fruto desta pesquisa é mais complexo e abrangente do que se conseguiu demonstrar pela descrição aqui produzida. A conclusão de melhor visibilidade é a de que é possível ampliar a pesquisa científica, baseada em técnicas de ‘Inteligência Artificial’, para aplicações na área fiscal.

No tema sobre a ampliação da capacidade de ferramentas para auditoria fiscal, deve-se destacar que é também possível projetar sistemas híbridos nesse contexto. Redes Neurais Artificiais são conhecidas como técnicas de modelagem baseadas em dados (HAYKIN, 1999). Pode-se combinar tais técnicas com outras baseadas em conhecimento. No caso aqui estudado, pode-se produzir regras de conhecimento semelhantes às seguintes (SILVEIRA, 2001):

‘Se $Ire < Ires$ ’ 0,80, então <VERIFIQUE SAÍDAS DESACOBERTADAS DE DOCUMENTAÇÃO FISCAL ou ENTRADAS FICTÍCIAS ou APROVEITAMENTO INDEVIDO DE CRÉDITO>’

‘Se $Irs < Irss$ ’ 0,80, então <VERIFIQUE SAÍDAS DESACOBERTADAS DE DOCUMENTAÇÃO FISCAL ou SUBFATURAMENTO ou ENTRADAS/SAÍDAS FICTÍCIAS>’

‘Se $Ame < Amep$ - 0,5, então <VERIFIQUE SAÍDAS FICTÍCIAS DE NOTAS FISCAIS INIDÔNEAS ou AQUISIÇÃO DE NOTAS FISCAIS COM OPERAÇÕES IRREGULARES>’

Onde Ire é o índice de recolhimento em relação às entradas; $Ires$ é o índice de recolhimento em relação às entradas do setor; Irs é o índice de recolhimento em relação às saídas; $Irss$ é o índice de recolhimento em relação às saídas do setor; Ame é a alíquota média de entrada; e $Amep$ é a alíquota média de entrada do período.

Existem vários outros indicadores que podem ser utilizados para dar maior alcance à qualificação da sonegação fiscal e que fornecem dados para que se possa avaliar financeiramente uma determinada empresa.

Associando técnicas de modelagem baseadas em dados (redes neurais) com outras baseadas em regras de conhecimento (TOWELL & SHAVLIK, 1993), com técnicas de raciocínio baseado em casos (AAMODT & PLAZA, 1994), com lógica fuzzy (ZADEH, 1965), e outras técnicas de inteligência artificial e computacional, é possível avançar sem fronteiras na direção de ferramentas cada vez mais eficientes e poderosas para uso no ambiente de auditoria fiscal.

7. Referências

1. SILVEIRA, M. R. M., “Sistema Neural para Quantificação e Qualificação da Sonegação Fiscal de ICMS em Empresas do Tipo Débito/Crédito”, Dissertação de Mestrado, UENF, 2001.
2. RUMELHART, D. E., HINTON, G. E., WILLIAMS, R. J., “Learning Representations by Backpropagation Errors”, *Nature*, 323:533-536, 1986.
3. HAYKIN, S., “Neural Networks, A Comprehensive Foundation”, Second Edition, Prentice Hall Inc., 1999.
4. PRINCIPE, J. C., EULIANO, N. R., LEFEBVRE, W. C., “Neural and Adaptive Systems”, John Wiley & Sons, Inc., 2000.
5. BISHOP, C. M., “Neural Networks for Pattern Recognition”, Oxford University Press, 2003.
6. NEVES, S., VICECONTI, P. E. V., “Contabilidade Avançada e Análise das Demonstrações Financeiras”, Frase Editora, São Paulo, 1998
7. ZADEH, L. A., “Fuzzy Sets”, *Information and Control*, 8, 338-353, 1965.
8. AAMODT, A., PLAZA, E., “Case-Based Reasoning: Foundational Issues, Methodological Variations, and System Approaches”, *AI Communications*, 7, 39-59, 1994.
9. TOWELL, G. G., SHAVLIK, J. W., “The Extraction of Refined Rules from Knowledge-Based Neural Networks”, *Machine Learning*, 13, 71-101, 1993.