

APLICAÇÃO DAS REDES NEURONAIS ARTIFICIAIS À AUDITORIA: REVISÃO DA LITERATURA

Carlos Miguel Dias Barros
Assistente de 2º Triénio no Instituto Superior de Contabilidade e Administração de Coimbra
Mestre em Contabilidade e Auditoria
cbarros@iscac.pt

Zélia Dias
Aluna finalista do Curso de Contabilidade e Auditoria do ISCAC

APLICAÇÃO DAS REDES NEURONAIS ARTIFICIAIS À AUDITORIA: REVISÃO DA LITERATURA

RESUMO

Uma rede neuronal artificial consiste no processamento de elementos (análogos aos neurónios do sistema neuronal biológico) inter conectados em rede. As redes neuronais artificiais possuem duas grandes forças: por um lado, são instrumentos poderosos na modelização e compreensão do comportamento cognitivo humano; por outro, têm fortes propriedades de reconhecimento de padrões, sendo capazes de reconhecer padrões mesmo entre dados variáveis, ambíguos e confusos (Refenes, 1995, citado por Koskivaara, 2000).

Por esta razão, a aplicação desta nova tecnologia à auditoria tem vindo a acentuar-se. O objectivo deste trabalho consiste em apresentar os fundamentos das redes neuronais artificiais, bem como as principais áreas de aplicação à auditoria.

Entre estas destaca-se a detecção de erros materialmente relevantes. Os auditores estabelecem a natureza, extensão, profundidade e oportunidade dos procedimentos de auditoria com base na investigação resultante de flutuações e relações que sejam inconsistentes com outra informação relevante ou que se desviem de quantias previstas. Ora, os modelos de redes neuronais permitem captar padrões relevantes detectados na informação financeira, estabelecendo correlações entre os dados dificilmente percebidas pelos meios tradicionalmente utilizados pelos auditores.

Outras áreas da auditoria em que as redes neuronais se têm mostrado instrumentos válidos de auxílio ao julgamento dos auditores são a avaliação do risco de gestão fraudulenta, a avaliação do princípio da continuidade e a avaliação do controlo interno da entidade auditada.

Palavras-chave: redes neuronais artificiais, avaliação de risco, princípio da continuidade, controlo interno

1. INTRODUÇÃO

As redes neuronais artificiais constituem uma tecnologia com tremendas capacidades de reconhecimento de padrões podendo assistir muito satisfatoriamente os auditores na geração de hipóteses e na procura de processos relacionados com aspectos financeiros, operacionais e de conformidade (Coakley e Brown, 2000).

O objectivo do presente trabalho consiste em apresentar uma panorâmica da aplicação das redes neuronais artificiais no âmbito da auditoria, com base nalguns estudos empíricos já realizados.

O aumento exponencial das transacções electrónicas verificado nos nossos dias lança novos desafios à auditoria. Evidentemente que este tipo de informação tem de ser auditada. Esta é uma das razões para que os auditores necessitem de utilizar mais sistemas informáticos e de desenvolver novos instrumentos de auditoria. Neste sentido, Koskivaara (2000) apresenta as redes neuronais como um novo método de auditoria, justificando esta sua afirmação: a auditoria necessita de capacidade de previsão, controlo e classificação; ora, as redes neuronais já demonstraram noutros domínios possuírem essas qualidades; a sua capacidade de adaptação, de modelização e compreensão do comportamento cognitivo humano e as suas propriedades de reconhecimento de padrões torna-a uma alternativa interessante a outros métodos.

Apesar das redes neuronais terem vindo a ser aplicadas a várias áreas de negócios (Vellido, Lisboa e Vaughan, 1999, resumem a literatura publicada entre 1992 e 1998 sobre aplicação das redes neuronais às diferentes áreas de negócio), no âmbito da auditoria são poucos os trabalhos existentes.

Começa-se por apresentar uma panorâmica das redes neuronais artificiais de forma a melhor se apreender as suas potencialidades quando aplicadas à auditoria. De seguida descrevem-se alguns trabalhos empíricos elaborados no âmbito de quatro vertentes da auditoria: a detecção de distorções materialmente relevantes, a avaliação do risco de gestão fraudulenta, a avaliação do princípio da continuidade e a avaliação do risco de controlo.

No ambiente litigioso que caracteriza os dias de hoje, emitir um tipo de relatório de auditoria errado pode acarretar graves consequências para o auditor. Os investigadores desta área têm produzido diversos modelos de previsão por forma a auxiliarem os auditores minimizando os riscos a que naturalmente estão expostos (Anandarajan e Anandarajan, 1999).


2. PANORÂMICA DAS REDES NEURONAI ARTIFICIAIS

As redes neuronais artificiais produzem informação através de um processo inspirado no sistema nervoso biológico. Todos nós podemos constatar que o cérebro humano tem uma capacidade superior à dos computadores digitais, sendo constituído por um elevado número de células nervosas (10^{11} , neurónios) de diferentes tipos (Hertz, 1991). Actualmente, as redes neuronais artificiais encontram-se numa fase de maturidade, constituindo-se como uma ferramenta importante para várias áreas científicas. São compostas por uma série de elementos simples de processamento, sendo cada um desses elementos conhecidos por neurónio artificial (Landau e Taylor, 1997).

Neurónio biológico

Os neurónios biológicos são constituídos por quatro elementos: as dendrites, núcleo, axónio e sinapses (Klerfors, 1998). O neurónio biológico recebe a informação (*inputs*) através das suas diversas dendrites, estas transmitem a informação para o núcleo da célula, que depois de tratada originará um *output* que seguirá através do axónio e será transmitido para os outros neurónios através de sinapses. O processo de transmissão de *output* ocorre quando as sinapses de um neurónio contactam com as dendrites de outros neurónios. A Figura 1 mostra de uma forma simplificada um neurónio biológico e a relação dos seus quatro elementos.

Figura 1 – Ilustração de um neurónio biológico



Fonte: Hertz (1991)

Assim, e à semelhança do cérebro humano, o elemento base de uma rede neuronal é o neurônio artificial. Este foi inspirado no neurônio biológico e simula as quatro funções. No Quadro I pode-se observar a correspondência entre os elementos de um neurônio biológico e de um neurônio artificial.

Quadro I – Correspondência entre os elementos de um neurônio biológico e artificial

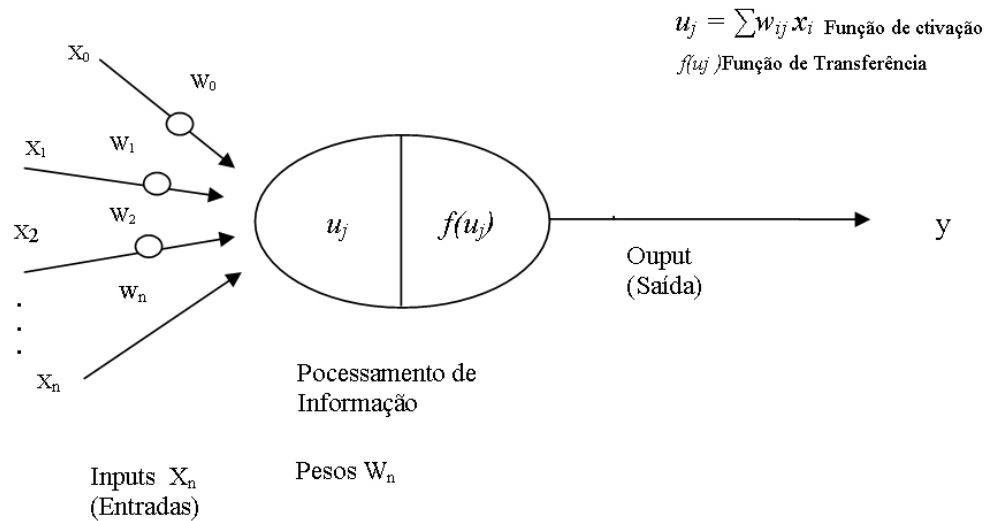
Neurônio Biológico	Neurônio Artificial
Sinapses	<i>Outputs</i> (saída de informação)
Axônio	Pesos
Núcleo	Processamento de informação
Dendrites	<i>Inputs</i> (entrada de informação)

Fonte: Gomm, Page e Williams (1993)

Neurônio Artificial

Um neurônio artificial é mais simples que um neurônio biológico. Assim, como se pode observar na figura 2, um neurônio tem vários *inputs* e um *output* (Koskivaara, 2000).

Figura II: Esquema de um neurónio artificial



Fonte: (Klerfors, 1998)

Uma rede neuronal é composta por uma série de neurónios artificiais que interagem através de uma densa rede de interligações. Cada neurónio tem um valor y , que é divulgado através de ligações para outros neurónios dentro da rede. (Koskivaara, 2004). Um neurónio recebe um conjunto de entradas (informações) representadas por x_1, x_2, \dots, x_n , ao qual está associado a cada uma dessas entradas um peso representado por w_1, w_2, \dots, w_n . A soma de todas as multiplicações dos *inputs* pelos correspondentes pesos designa-se por activação do neurónio, a qual é efectuada por uma função de activação. Esta transmite-nos o valor da rede. Este valor é imediatamente transformado através de uma função de transferência, que produz o *output* y do neurónio (Koshivaara, 2004, Gomm, Page e Williams, 1993; Fu, 1994).

Estrutura/arquitectura das redes neuronias

Uma vez definida a estrutura de um neurónio artificial, elemento básico de uma rede neuronal artificial, descreve-se, agora, a forma como estes se dispõem. Os neurónios artificiais numa rede neuronal estão organizados por camadas. Cada modelo está intimamente relacionado com processo de aprendizagem. Uma rede neuronal consiste numa inter conexão de vários elementos simples, dispostos por camadas, sendo que o número de camadas e o modo como eles se ligam, define um modelo específico¹ (Pereira, 1996). De seguida descreve-se brevemente a organização mais usual: a Rede Neuronal de Múltipla Camada.

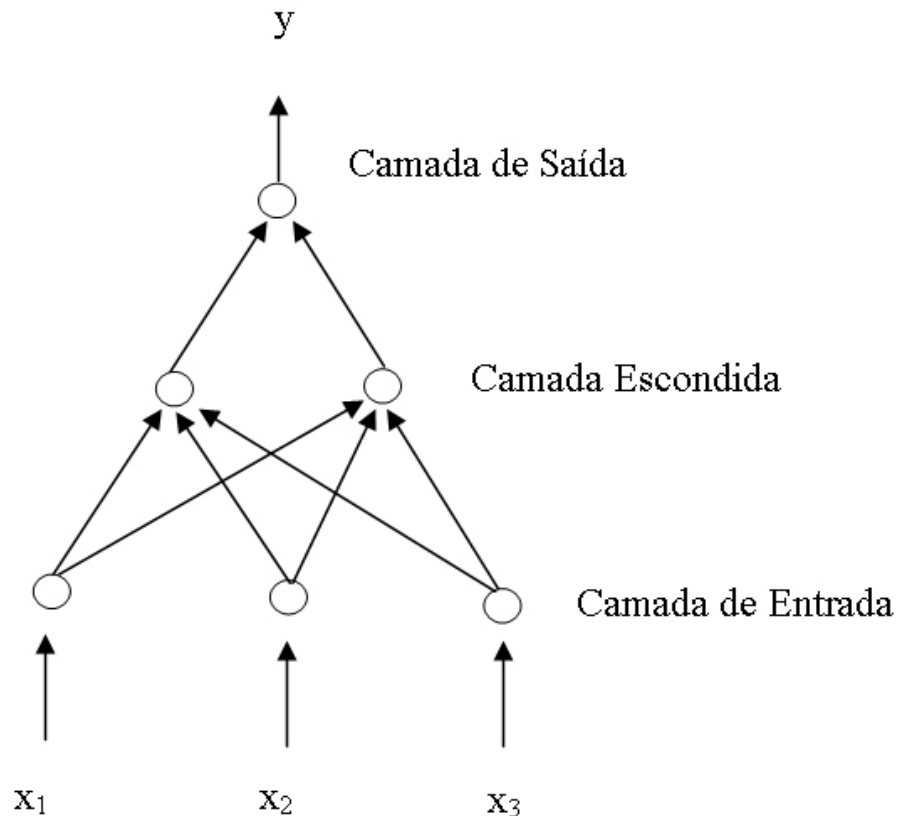
A estrutura de uma Rede Neuronal de Múltipla Camada consiste em organizar os neurónios por camadas (ver Figura IV), em que cada elemento de processamento (neurónio) de cada camada está ligado a elementos da camada seguinte, estando associado um peso a cada ligação (Pereira, 1996).

A primeira camada é conhecida por camada de entrada (*input layer*) e a última camada por camada de saída (*output layer*). As camadas intermédias (uma ou mais) são designadas por camadas escondidas (*hidden layers*). Estas dão às redes neuronais a característica da não linearidade (Koskivaara, 2000). O termo "escondido" advém do facto de as entradas e saídas das camadas escondidas serem internas à rede. Constituem parâmetros específicos da rede o número de camadas e o número de neurónios artificiais de cada camada (Ribeiro, 1995).

¹ Nas redes neuronias existem quatro modelos diferentes: Redes Neuronais de Uma Camada; Redes Neuronais de Múltipla Camada, Redes Neuronais Recorrentes e Redes Neuronais Competitivas (Pereira, 1996).

Um conjunto de informação é introduzido na rede neuronal através da camada de entrada. A camada de entrada comunica para uma ou mais camadas intermédias onde o processamento da informação é realizado. A camada escondida é composta por elementos de processamento (nós) que operam em paralelo e realizam muito do trabalho da rede neuronal. A camada escondida comunica com a camada de saída a qual transmite a resposta, tipicamente como uma classificação ou uma previsão. Esta pode representar sinais de compra/venda financeiras, previsões do movimento da taxa de câmbio, etc. (Ramamoorti, 1999).

Figura IV – Estrutura de uma rede neuronal de múltipla camada



Fonte: (Koskivaara, 2004)

As redes neuronais caracterizam-se pelas suas elevadas velocidades de computação. No entanto, muitas outras vantagens lhes são imputadas, entre as quais se destacam:

- **Não Linearidade:** a rede neuronal é composta por neurónios, estes elementos são não lineares (Pereira, 1996).
- **Capacidade de apreender informação através de exemplos:** o mecanismo de aprendizagem é muitas vezes executado através de uma apropriada adaptação dos pesos dentro das sinapses do modelo do neurónio artificial (Gomm, Page e Williams, 1993).
- **Capacidade de generalizar para novos *inputs*** (Gomm, Page e Williams, 1993).
- **Tolerância a falhas:** a rede neuronal é constituída por muitos nós de processamento, cada um com conexões bastante simples, quando ocorrem estragos num dos nós ou ligações, estes não prejudicam significativamente o desempenho global. (Pereira, 1996).
- **Facilmente implementáveis em tecnologia:** devido à sua característica altamente paralela. (Pereira, 1996).

As redes neuronais conseguem organizar, classificar, transformar e apreender (através de descrições qualitativas e quantitativas de objectos, conceitos ou eventos). Estas resolvem problemas através auto-aprendizagem e auto-organização (Fu, 1994).

As redes neuronais podem-se aplicar a imensos campos, normalmente quando o método tradicional não consegue resolver o problema. Neste caso particular destacamos a sua utilidade na área financeira e de auditoria.

Aprendizagem

As redes neuronais possuem a capacidade de aprender tal como os humanos. O processo de aprendizagem² numa rede neuronal pode ser visto como um problema de adaptar a arquitectura e os pesos das ligações neuronais para que a rede possa resolver um problema específico eficientemente. Numa rede neuronal a aprendizagem incide na alteração de pesos atribuídos às ligações entre neurónios, podendo vir a existir alteração de estrutura. Pereira (1996) identifica genericamente três fases do processo de aprendizagem:

- “A rede neuronal é estimulada pelo ambiente que a rodeia;
- Como resultado aos estímulos recebidos, a configuração da rede é alterada;
- A rede neuronal irá responder de modo diferente a novas situações, devido às alterações na sua estrutura”

As redes neuronais têm a capacidade de aprender regras subjacentes a um conjunto de exemplos representativos e esta é uma grande vantagem das redes neuronais relativamente a outros sistemas de inteligência artificial.

“As redes são treinadas, isto é, aprendem a produzir a saída desejada a partir de um conjunto de dados de entrada, designado por conjunto de treino. Este processo consiste em a rede neuronal identificar as relações entre as entradas e as saídas de um sistema. A partir daqui a rede é capaz de generalizar de modo a agir correctamente quando sujeita a novos dados” (Pereira, 1996).

3. APLICAÇÃO DAS REDES NEURONAIS ARTIFICIAIS À AUDITORIA

A principal aplicação das redes neuronais à auditoria relaciona-se com a detecção de distorções materialmente relevantes, instrumento de avaliação de fraude na gestão, sinalização de problemas relacionados com o princípio da continuidade. As redes neuronais também podem ser aplicadas na avaliação de risco de controlo.

3.1. DETECÇÃO DE DISTORÇÕES MATERIALMENTE RELEVANTES

Esta é a área da auditoria onde é feita uma maior aplicação das redes neuronais (Koskivaara, 2004). O auditor dirige os recursos de auditoria para as áreas que apresentam maior susceptibilidade de ocorrência de distorções materialmente relevantes. As Normas Técnicas de Revisão/Auditoria indicam que “o revisor/auditor deve planejar o trabalho de campo e estabelecer a natureza, extensão, profundidade e oportunidade dos procedimentos a adoptar, com vista a atingir o nível de segurança que deve proporcionar e tendo em conta a sua determinação do risco da revisão/auditoria e a sua definição dos limites de materialidade” (par. 15).

Nesse sentido, o auditor deve aplicar procedimentos analíticos, isto é, deve proceder à “*análise de rácios e tendências significativos incluindo a investigação resultante de flutuações e relações que sejam inconsistentes com outra informação relevante ou que se desviem de quantias previstas*” (NIR 520, IFAC, par. 3.). Ora, a aplicação das redes neuronais possibilita a previsão de valores futuros auxiliando, neste sentido, o auditor na formação de expectativas.

Coakley (1995), citado por Koskivaara (2000), aplicou as redes neuronais a uma amostra de rácios financeiros mensais, de um período de quatro anos, relativos a uma empresa do sector da distribuição, de média dimensão. Os dados dos três primeiros anos foram usados para a aprendizagem, sendo os do quarto ano usados como os dados previstos pela rede de forma a avaliar a sua capacidade de previsão. Comparando os resultados com procedimentos analíticos tradicionais, obteve evidência de que a utilização das redes neuronais possibilitam mais informação sobre a presença de erros materiais do que os processos analíticos tradicionais, bem como um conhecimento mais profundo das plausíveis causas do erro.

Um outro trabalho levado a cabo em Taiwan por Wu (1997) investigou a performance das redes neuronais no âmbito da auditoria interna dos serviços fiscais desse país. Os auditores fiscais, com

² Podem-se distinguir três tipos de aprendizagem que são a aprendizagem supervisionada, reforçada e não supervisionada. (Ribeiro, 1995; Koskivaara 2004).

base em diversas informações financeiras, entre as quais o balanço, a demonstração dos resultados e alguns rácios têm de decidir se efectuam uma auditoria mais profunda de cada entidade ou não, consoante a avaliação de risco realizada. Estas decisões são bastante relevantes uma vez que implicam recursos de auditoria substanciais. De acordo com a autora, à data do seu trabalho existiam poucos peritos com conhecimentos capazes de tomar, neste âmbito, as decisões mais acertadas, sustentando que a utilização de redes neuronais artificiais podiam contribuir para a resolução do problema. O modelo de rede neuronal é aplicado na classificação dos casos fiscais baseando-se nalguns sinais. O *output* do modelo consiste na decisão de auditoria: necessidade, ou não, de aprofundar a auditoria.

A autora utilizou na sua investigação 180 casos devidamente documentados, sendo que em 90 desses casos os peritos tinham decidido aprofundar mais a auditoria e nos outros 90 não. Metade dos casos foi utilizada na fase de aprendizagem do modelo e a outra metade na avaliação dos resultados por ele produzidos. Os *inputs* utilizados consistiram em 16 atributos da informação financeira (e.g., margem bruta sobre as vendas, suprimentos, empréstimos de curto prazo). Comparando os *outputs* do modelo com as decisões tomadas pelos peritos, o modelo mostrou ter uma capacidade de previsão de 95%, o que levou a autora concluir que os 16 atributos são eficazes como sinais de evasão fiscais.

Koskivaara (2000) desenvolveu um trabalho no sentido de construir um instrumento de auditoria baseado nas redes neuronais que previsse e reconhecesse padrões nas rubricas dos balanços mensais. O objectivo é auxiliar o auditor na fase de planeamento fornecendo informação objectiva para a tomada de decisões, com base nos *inputs* do modelo. Os dados utilizados pelo autor consistiram 72 balanços mensais de uma determinada empresa, sendo o objectivo o reconhecimento de dinâmicas e relações entre diferentes contas. Para testar o modelo, o autor introduziu erros nos dados utilizados. Koskivaara (2000) não comparou os resultados do modelo com nenhum outro método pelo facto de diversos autores sustentarem que a tecnologia das redes neuronais é muito competitiva quando comparada com os métodos standard na análise de informação financeira e, por outro lado, porque as técnicas como a análise de regressão têm sido muito pouco utilizadas na prática (Ameen e Strawser, 1994). Os resultados mostraram que a aplicação das redes neuronais no reconhecimento de dinâmicas e de relações entre diversas rubricas das demonstrações financeiras é eficaz.

3.2. AVALIAÇÃO DO RISCO DE GESTÃO FRAUDULENTA

O auditor, no decurso do seu trabalho, deve considerar o risco de distorções materiais nas demonstrações financeiras resultantes de fraudes ou erros (NIR 240, par. 2). A fraude significa um acto intencional levado a cabo por um ou mais indivíduos pertencentes ao órgão de gestão, empregados ou terceiros, envolvendo o uso de intenção deliberada para obter uma vantagem injusta ou ilegal (NIR 240, par. 4), podendo envolver (NIR 240 A, par. 3):

- *“Manipulação, falsificação ou alteração de registos ou documentos;*
- *Apropriação indevida de activos;*
- *Supressão ou omissão dos efeitos de transacções nos registos ou documentos;*
- *Registo de transacções sem substância;*
- *Má aplicação de políticas contabilísticas”.*

A mesma norma (NIR 240 A, pars. 5 e 6) esclarece que a responsabilidade primária pela prevenção e detecção de fraudes e erros é do órgão de gestão, através da implementação e do funcionamento continuado de sistemas contabilístico e de controlo interno adequados, e não do auditor, embora a auditoria anual funcione como um dissuasor.

Com o objectivo de desenvolver um modelo de rede neuronal eficaz na classificação de fraude com base em informações financeiras da entidade auditada, Green e Choi (1997) levaram a cabo uma investigação focalizada na fase de planeamento de auditoria. Atendendo a que a maioria dos casos de fraude afectam não apenas uma, mas diversas contas ou ciclos de transacções, os autores entendem vantajosa a aplicação das redes neuronais na avaliação do risco de fraude, quando comparada com os procedimentos analíticos individualmente, pelo facto de permitirem examinar simultaneamente mudanças e relações entre diversas contas ou grupos de contas das demonstrações financeiras.

A partir de informação financeira de uma amostra de entidades onde ocorreram fraudes e de outra em que não ocorreram, as redes neuronais aprendem a reconhecer os padrões da informação financeira em cada uma das situações. Desta forma, depois de testadas em casos concretos, servem de modelo

de previsão de existência ou não de fraude nas demonstrações financeiras de determinada entidade. No caso do modelo classificar as demonstrações financeiras como fraudulentas, o auditor atende a esse sinal na sua avaliação do risco de fraude, incrementando os recursos de auditoria na área em causa.

Como *inputs* do modelo, Green e Choi (1997) seleccionaram cinco rácios e três contas das demonstrações financeiras. Os resultados encontrados pelos autores indicam que as redes neuronais permitem reduzir os sinais falsos de fraude, mantendo os mesmos níveis de confiança, ou excedendo-os, de anteriores investigações. Tais resultados permitem aos auditores a afectação de recursos de auditoria a áreas com maior risco, pelo que as redes neuronais têm um grande potencial como instrumento de avaliação e detecção de fraude.

Outro trabalho que desenvolveu um modelo de redes neuronais para detectar indícios de gestão fraudulenta foi o de Fanning e Cogger (1998). Com o objectivo de incrementar o conhecimento sobre os sinais de demonstrações financeiras fraudulentas através da informação obrigatoriamente disponibilizada pelas empresas, os autores encontraram vinte indicadores de demonstrações financeiras fraudulentas. Na fase de aprendizagem do modelo utilizaram 150 empresas, sendo de 54 o número das empresas empregues na fase de teste. O modelo de redes neuronais desenvolvido obteve probabilidades de previsão mais elevadas do que outros modelos alternativos assentes em instrumentos estatísticos como a análise discriminante linear e quadrática, e a regressão logística.

3.3. AVALIAÇÃO DO PRINCÍPIO DA CONTINUIDADE

O auditor deve tomar em consideração a adequação do pressuposto de continuidade subjacente à preparação das demonstrações financeiras quando planear e executar procedimentos de auditoria e avaliar os respectivos resultados (NIR 570, IFAC).

A mesma norma indica que a *“responsabilidade do revisor/auditor é a de considerar a adequação do uso pela gerência do pressuposto da continuidade na preparação das demonstrações financeiras, e considerar se existem ou não incertezas materialmente relevantes acerca da capacidade da entidade em prosseguir como continuidade que necessita de ser divulgada nas demonstrações financeiras”* (NIR 570, IFAC).

A aplicação das redes neuronais na avaliação, pelo auditor, da capacidade da empresa em prosseguir a actividade no futuro previsível tem sido mínima. Contudo esta área assemelha-se ao estudo das falências, sobre a qual existe uma grande utilização das redes neuronais. O auditor, quando julga haver uma incerteza materialmente relevante que pode lançar dúvida significativa sobre a capacidade da entidade prosseguir em continuidade e a empresa não divulgar adequadamente a existência dessa incerteza, deve expressar uma opinião com reservas ou adversa (NIR 570, IFAC). Existem, no entanto, diferentes graus de dúvida sobre a capacidade da entidade prosseguir em continuidade.

Muitos autores têm desenvolvido modelos de previsão dos relatórios de auditoria a serem emitidos pelos auditores relativamente ao princípio da continuidade (com reservas ou sem reservas). Anandarajan e Anandarajan (1999) estenderam esta área de investigação comparando três modelos que visam auxiliar os auditores na decisão da escolha de tipo de relatório a emitir: com reservas ou sem reservas no que respeita ao princípio da continuidade. Um dos modelos baseia-se nas redes neuronais artificiais, outro em sistemas inteligentes e outro ainda em análise discriminante múltipla. Para validar os diferentes modelos os autores compararam a capacidade de previsão demonstrada por cada um na escolha do tipo de relatório que deveria ser emitido para o cliente em causa. Para o efeito seleccionaram 45 empresas com relatórios com ênfases, reservas ou adversos e outras 45 cujos relatórios de auditoria estavam “limpos” no que respeita, em ambos os grupos, ao princípio da continuidade. Os resultados indicam ser o modelo de redes neuronais artificiais o que apresenta melhor capacidade preditiva dos três modelos em análise, constituindo, por isso, um útil instrumento de prova analítica ao dispor do auditor.

Etheridge et al (2000) examinaram como os auditores podem usar as redes neuronais artificiais como procedimentos analíticos na avaliação do princípio da continuidade e compararam a capacidade de três abordagens de redes neuronais artificiais (*backpropagation*, *categorical learning* e *probalistic neural network*) na classificação da viabilidade financeira futura de clientes em continuidade como instrumentos de ajuda e suporte do julgamento dos auditores sobre essa matéria. Os critérios seguidos para comparar as três abordagens foram: a taxa de erro global de classificação e os custos estimados relacionados com os erros de classificação, isto é, os custos estimados com uma errónea decisão de considerar uma empresa insolvente como solvente e vice-versa. A amostra utilizada pelos autores

consistiu em 57 rácios financeiros dos exercícios 1986-1988 de 1139 bancos de diversas regiões dos EUA, dos quais 991 se mostravam bem financeiramente e 148 vieram a falir em 1989. Aplicando o critério da taxa de erro global de classificação a *probabilistic neural network* mostrou-se ser a abordagem mais consistente, seguindo-se a *backpropagation network* e a *categorical learning network*. Quando considerado o critério dos custos estimados relacionados com os erros de classificação a *categorical learning network* foi a que apresentou mais baixos custos, seguindo-se a *backpropagation network* e a *probabilistic neural network*. Estes resultados suportam a importância das taxas de erro de classificação das empresas como solventes/insolventes e mostram como as diferentes arquitecturas das redes neuronais podem reduzir ou aumentar os custos derivados dos erros de classificação. A probabilidade de falência utilizada no estudo, bem como a composição da amostra poderiam alterar os resultados obtidos, constituindo, por isso, limitações desta investigação.

3.4. AVALIAÇÃO DO RISCO DE CONTROLO

Na avaliação do risco de controlo, isto é, o risco de o sistema de controlo interno não detectar e corrigir distorções materialmente relevantes, os auditores consideram habitualmente um determinado conjunto de factores de risco. A conjugação dos diversos factores de risco, medidos através de informação intrinsecamente diferente, torna a avaliação do risco de controlo uma tarefa de difícil execução. A avaliação do risco de controlo é um processo sistemático que exige a aplicação do julgamento profissional sobre factores de risco relevantes.

Com o objectivo de examinar se a experiência dos auditores influencia a forma de abordar a selecção de informação relevante e se essa informação conduz a avaliações de risco de controlo mais acertadas, Davis (1996) desenvolveu dois modelos de redes neuronais: um com base nos dados obtidos junto de 37 auditores com pouca experiência (até dois anos de experiência) e outro com base nas observações de 27 auditores seniores experientes (com cinco ou mais anos de experiência). Os *inputs* do modelo consistiram em factores de risco seleccionados pelos auditores relacionados com o ambiente de controlo, sistema informático, controlos contabilísticos, entre outros. Os auditores foram submetidos a uma experiência comportamental através de um caso de uma empresa comercial, na área das vendas. Entre os 107 factores de risco apontados no caso, cada auditor tinha de escolher os que, de acordo com o seu julgamento, melhor representavam a estrutura de controlo interno da empresa em causa, de forma a avaliarem, através de um programa informático, o risco de controlo preliminar. Os resultados manifestam que ambos os modelos de redes neuronais foram capazes de captar o conhecimento dos auditores através dos factores de risco seleccionados para efeitos da avaliação preliminar do risco de controlo, ou seja, o modelo mostrou-se preciso nas previsões dos julgamentos dos auditores.

Com o propósito de avaliar a aplicação das redes neuronais à avaliação do risco no contexto da auditoria interna, Ramamoorti e Traver (1998) (ver também Ramamoorti, Bailey e Traver, 1999) desenvolveram uma investigação financiada pelo *Institute of Internal Auditors* levada a cabo nos departamentos de uma universidade pública. O objectivo do modelo consistia em classificar os departamentos com maior risco, por forma a serem alocados para os mesmos mais recursos de auditoria. Dos 141 departamentos utilizados como amostra da investigação, 70% foram afectos à fase de aprendizagem do modelo e os restantes 30% à sua validação. As variáveis que serviram de *input* foram obtidas a partir do sistema financeiro e administrativo da universidade (variáveis quantitativas) e seleccionadas pelos auditores internos (variáveis qualitativas, factores de risco). A investigação englobou, também, a comparação dos resultados obtidos utilizando as redes neuronais com os obtidos pelos métodos estatísticos tradicionais, como a regressão linear múltipla e a regressão logística. Os resultados da aplicação do modelo tiveram como fim identificar os 25 departamentos com maior risco, tendo tido uma taxa de precisão de 72 a 84%. Estes resultados levaram os autores a concluir que os auditores internos podem beneficiar da utilização das redes neuronais na avaliação do risco.

4. CONCLUSÕES

Com o intuito de examinar as potencialidades das redes neuronais quando utilizadas como instrumento de auxílio do auditor no processo de auditoria, efectuou-se a revisão da literatura relevante sobre o tema, não deixando de apresentar uma breve panorâmica do que são as redes neuronais artificiais.

Pela avaliação dos trabalhos revistos conclui-se que esta nova tecnologia emergente constitui um instrumento eficaz de auditoria. A capacidade para aprender com o exemplo e a aptidão para a

generalização permitem o reconhecimento de padrões mesmo entre dados incompletos, tornando as redes neuronais artificiais aplicações muito atractivas em diversos campos da auditoria, nomeadamente na sinalização de erros materialmente relevantes, na avaliação do risco de gestão fraudulenta, na avaliação do princípio da continuidade e na avaliação do controlo interno da entidade auditada.

Como se explicita no próprio título, o presente trabalho teve como objectivo apenas o de conhecer o contexto das aplicações das redes neuronais à auditoria através de alguns dos trabalhos de investigação já publicados. Não se conhece qualquer investigação de âmbito nacional que tenha estudado na prática a utilização das redes neuronais em auditoria, pelo que se conclui ser esta uma área de interesse para futuras investigações.

BIBLIOGRAFIA

- Ameen, Elsie C, Strawser, Jerry R (1994) "Investigating the use of analytical procedures: An update and extension", *Auditing: Fall*, Vol. 13, pp. 69-77.
- Anandarajan, M., Anandarajan, A., (1999) "A comparison of machine learning techniques with a qualitativa response model for auditor's going concern reporting", *Expert Systms with Applications*, Vol. 16, pp 385-392.
- Coakley, James e Brown, Carol (2000) "Artificial Neural Networks in Accounting and Finance: Modeling Issues", *International Journal of Intelligent Systems in Accounting, Finance & Management*, Vol. 9, 119-144.
- Davis, J. T. (1996) "Experience and auditors' selection of relevant information for preliminary control risk assessment", *Auditing*, Vol. 15, pp. 16-37.
- Fanning, Kurt e Cogger, Kenneth (1998) "Neural Network detection of management fraud using published financial data", *International Journal of Intelligent Systems in Accounting, Finance & Management*, Vol. 7, 21-41.
- Fu, LiMin (1994); "Neural Networks in Computer Intelligence"; McGraw – Hill International Editions.
- Gomm, J.B.; Page, G.F. e Williams, D., (1993); "Introduction to neural networks"; Chapman & Hall.
- Green, Brian Patrick e Choi, Jae Hwa (1997) "Assessing the risk of management fraud through neural network technology", *Auditing*, Vol. 16, pp. 14-28.
- Hertz, John; Krogh, Anders e Palmer; Richard G. (1991); "Introduction to the theory of neural computation"; Persus Publishing.
- International Federation of Accountants (IFAC) (?), Norma Internacional de Revisão/Auditoria (NIR) 240, *Fraudes e Erros*. In: Manual do Revisor Oficial de Contas, OROC, CD-ROM edição 19.
- International Federation of Accountants (IFAC) (?), Norma Internacional de Revisão/Auditoria (NIR) 520, *Procedimentos Analíticos*. In: Manual do Revisor Oficial de Contas, OROC, CD-ROM edição 19.
- International Federation of Accountants (IFAC) (?), Norma Internacional de Revisão/Auditoria (NIR) 570, *Princípio da Continuidade*. In: Manual do Revisor Oficial de Contas, OROC, CD-ROM edição 19.
- Klerfors, Daniel (1998), "Artificial Neural Networks", Saint Louis University, School of Business & Administration.
- Koskivaara, Eija (2000), "Artificial neural network models for predicting patterns in auditing monthly balances", *Journal of the Operational Research Society*, Vol. 51, pp. 1060-1069.
- Koskivaara, Eija (2004), "Artificial neural networks in analytical review procedures", *Managerial Auditing Journal*, Vol.19, No. 2: 191 – 223.
- Landau, L.J.; Taylor J. G. (1998); "Concepts for Neural Networks a Survey", Springer – Verlag London Limited.

- Landau, Lawrence Jay; Taylor John Gerald, (1998), "Concepts for neural networks", Springer, Verlag London Limited.
- Pereira, Carlos Manuel Jorge da Silva, (1996), "Aprendizagem em tempo real de redes neuronais aplicada à identificação e controlo de sistemas", Dissertação de Mestrado em Sistemas e Automação, Universidade de Coimbra.
- Ramamoorti, Sridhar e Traver, Richard O. (1998), *Using Neural Networks for risk assessment in internal auditing: A feasibility study*, The Institute of Internal Auditors Research Foundation: Florida.
- Ramamoorti, Sridhar; Bailey, Andrew e Traver, Richard O. (1999) "Risk assesement in internal auditing : A neural network approach", *International Journal of Intelligent Systems in Accounting, Finance & Management*, Vol. 8, 159-180.
- Ribeiro, Bernadete Martins; (1995); "Contribuição para a Modelização, Supervisão e Controlo de Sistemas Multivariáveis não Lineares por Redes Neuronais com Aplicação a um Forno de Cal", Tese para a obtenção do grau de Doutor em Ciências de Engenharia na Área de Engenharia Electrotécnica Especialidade de Informática, Universidade de Coimbra.
- Vellido, A., Lisboa, P.G.G. e Vaughan, J., (1999) "Neural Networks in business: a survey of applications (1992-1998)", *Expert Systms with Applications*, Vol. 17, pp 51-70.
- Wu, Rebecca C. (1997) "Neural networks models: Foundations and applications to an audit decision problem", *Annals of Operations Research*, 75, pp. 291-301.