

**ESCOLA DE ADMINISTRAÇÃO DE EMPRESAS DE SÃO PAULO  
FUNDAÇÃO GETÚLIO VARGAS**

**REDES NEURAIS : APLICAÇÕES EM FINANÇAS**

**RELATÓRIO FINAL**

**Pedro Luiz Gazoni  
12.961.013-4  
Projeto de Iniciação Científica  
Prof. William Eid  
Junho de 1999**

# Sumário

<i>Introdução</i>	3
<i>Justificativa da Pesquisa</i>	4
Objetivos da Pesquisa	5
Metodologia da Investigação e Fontes	6
<i>Sobre Redes Neurais</i>	7
<b>Analogia Biológica</b>	7
Redes Neurais Biológicas	7
Redes Neurais Artificiais	8
<b>Estruturas e Componentes de Redes Neurais</b>	9
Elementos Processadores	9
Rede	9
Estrutura de Rede	10
Processando Informação na Rede	10
Função somatória	11
Função de Transformação ( Transferência)	11
Aprendizagem	12
<b>Virtudes e Fraquezas de uma RNA</b>	13
<b>Desenvolvimento de Aplicações em Redes Neurais</b>	16
Estruturas de Rede	17
Sistemas de Memória Associativa	17
Camada Oculta	18
Estrutura de Dupla Camada	18
<b>Algoritmos de Aprendizagem</b>	19
<b>Como uma Rede Aprende</b>	20
<b>Treinando a Rede</b>	22
<b>Implementação</b>	24
<b>Sobre os paradigmas da computação neural</b>	25

<b>Programando Redes Neurais</b>	<b>26</b>
<b>Hardware de Redes Neurais</b>	<b>27</b>
<b>Situação das Redes Neurais Artificiais</b>	<b>29</b>
<b><i>Redes Neurais na análise de condição financeira</i></b>	<b>30</b>
<b>Papel das Redes Neurais na análise de condição financeira</b>	<b>30</b>
<b>Exemplos da utilização de Redes Neurais na análise de condição financeira</b>	<b>32</b>
Creditview	32
Análise de índices no processo de revisão analítica e Redes Neurais	33
Reconhecimento de padrões de dificuldade financeira	34
<b><i>Redes Neurais na previsão de falências</i></b>	<b>35</b>
Previsão de falência através de uma Rede Neural	35
Previsão de falências: uma comparação com análise discriminante	36
<b><i>Redes Neurais e o risco de dívidas</i></b>	<b>37</b>
Classificação de títulos: uma aplicação não-conservadora de Redes Neurais	37
Classificação de Títulos com Redes Neurais	38
<b><i>As Redes Neurais no Mercado de Títulos</i></b>	<b>39</b>
Prevendo a performance do preço de ações: uma aproximação por Redes Neurais	39
Testabilidade da APT através de Redes Neurais	40
<b><i>Previsões financeiras e a utilização de Redes Neurais</i></b>	<b>41</b>
Redes Neurais como alternativa à regressão	41
Administrando Estratégias de Previsão de taxas de câmbio com Redes Neurais	42
<b><i>Conclusão</i></b>	<b>43</b>
<b>Revisão Bibliográfica</b>	<b>44</b>

## Introdução

Muitos dos primeiros pesquisadores de Redes Neurais foram inspirados inicialmente pela similaridade entre arquitetura de Redes Neurais e seus paradigmas de aprendizagem com os do cérebro humano. Apesar de a maioria das primeiras tentativas de se aplicar Redes Neurais à tomada de decisão financeira ter sido ingênua, atrapalhada e geralmente malsucedida, inovações recentes na tecnologia e melhoramentos em nosso entendimento dos pontos fortes e fracos de Redes Neurais quando comparadas à outras formas de aprendizagem de máquinas ou de processos humanos de tomada de decisão estão resultando em sistemas comercialmente bem sucedidos.

As Redes Neurais compõem uma técnica altamente flexível e de aplicações incrivelmente variadas para as quais há um enorme número de benefícios potenciais a serem oferecidos.

Um importante aspecto das Redes Neurais é sua capacidade de estabelecer relações não-lineares entre os dados de entrada e o objetivo a ser produzido.

Poderíamos definir Redes Neurais, primariamente, como sendo uma técnica de processamento de dados a mapear, ou relatar, um tipo de entrada ou fluxo de informação para a produção de um fluxo de saída.

Então, Redes Neurais englobam muitas características desejáveis como as de análise de dados dentro de um esquema de implementação eficiente em termos de velocidade de computação e de uso de memória dos computadores. Assim, essa técnica vem a chamar a atenção e o interesse da comunidade financeira e de economistas que têm historicamente procurado no desenvolvimento de caminhos da Inteligência Artificial aplicações em seus campos de trabalho para os modelos de sistemas.

## **Justificativa da Pesquisa**

Os serviços financeiros estão se tornando cada vez mais dependentes de tecnologias avançadas de computação para estabelecer e manter competitividade numa economia global. Redes Neurais representam uma excitante tecnologia nova com um grande potencial para uma variedade enorme de aplicações em finanças que podem ir desde uma rotineira análise de crédito até a decisão de estratégias na administração de um portfolio de grande escala. Algumas dessas aplicações já têm trazido ganhos dramáticos de produtividade.

Redes Neurais são especialmente adequadas na simulação de inteligência no reconhecimento de padrões, atividades de associação e de classificação. Problemas geralmente presentes nas áreas de análise de crédito, investimentos em títulos e de previsão financeira.

Vale dizer ainda que após 1989 quando o Departamento de Defesa norte-americano embarcou em um projeto multimilionário de pesquisas em redes neurais, o segundo maior patrocinador de pesquisas em aplicações de redes neurais têm sido organizações financeiras.

Ademais, ainda percebemos que o mercado não se utiliza dessa ferramenta em sua total extensão e de forma a maximizar suas vantagens mesmo com tantas pesquisas no âmbito acadêmico apontando para diversas aplicações práticas dos conceitos envolvidos.

## Objetivos da Pesquisa

Este trabalho visa, através da pesquisa bibliográfica, compilar de diversas fontes uma coleção de pesquisas, estudos e artigos que foquem a utilização da tecnologia de Redes Neurais para se melhorar a tomada de decisão em Finanças.

Assim, espera-se que o estudo venha a ser importante fonte de consulta para analistas financeiros, profissionais de sistemas de informação que estejam ou venham a trabalhar com essas aplicações de Redes Neurais e administradores que tenham responsabilidades de tomadas de decisão financeiras e que queiram estar em dia com os novos desenvolvimentos do campo.

Para uma melhor definição dos objetivos, dividiu-se a pesquisa nas seguintes seções:

Redes Neurais – Definir. Descrever os fundamentos para analistas financeiros. Apresentar Sistemas Artificiais Neurais como ferramenta para tomada de decisão financeira. Mostrar como aplicar Redes Neurais.

Descrever a aplicação de Redes Neurais na análise de condição financeira.

Descrever a aplicação de Redes Neurais na predição de falências.

Descrever a aplicação de Redes Neurais na determinação do risco de dívidas. Mostrar seu uso na classificação de títulos como debêntures.

Descrever a aplicação de Redes Neurais no Mercado de Títulos. Apresentar seu uso em previsões do preço de ações e no teste do APT (Arbitrage Pricing Theory).

Descrever a aplicação de Redes Neurais em previsões financeiras. Mostrá-las em seu uso como alternativa à regressão, em previsão de séries temporais e na previsão de mercados de câmbio.

Conclusão. Pretende-se discorrer sobre o tema, versando sobre sua importância e implicações futuras ao mercado financeiro.

## Metodologia da Investigação e Fontes

A metodologia escolhida consiste em uma pesquisa bibliográfica, que será efetuada em artigos, livros, dissertações publicados e que tratam do tópico de Redes Neurais e suas aplicações no campo de Finanças.

A apresentação de diversos trabalhos e sua abordagem em suas características principais visa mostrar o que vem sendo desenvolvido neste tópico por estudiosos de todo o mundo.

Explicar-se-á detalhadamente os conceitos relativos à Redes Neurais contidos neste estudo, além de conceitos próprios do mercado financeiro que venham a ser necessários para o entendimento completo da obra.

Casos reais de aplicações de Redes Neurais serão apresentados como ilustrativos da viabilidade e da eficiência deste tipo de aproximação para certas áreas de tomada de decisão financeira.

A pesquisa irá conter também indicações para os principais livros que aprofundam-se no tema, além, é claro, de referências aos artigos e dissertações utilizados na elaboração do projeto.

## **Sobre Redes Neurais**

### **Analogia Biológica**

#### **Redes Neurais Biológicas**

O cérebro animal (e humano) é formado por células especiais, os neurônios, específicas, pois não morrem. O resto de nossas células se reproduz para se substituir e, então, morre. Há a possibilidade de que nossa capacidade de reter informações esteja ligada a essa característica dos neurônios. Diversos tipos de neurônios são conhecidos e o total deles no cérebro estima-se ser de até 100 bilhões. O funcionamento dos neurônios se dá através de agrupamentos chamados de redes. Essas redes são formadas por milhares de neurônios interconectados. Por esse ponto de vista, pode-se definir o cérebro como uma coleção de Redes Neurais.

A habilidade de aprender e de reagir a estímulos ambientais requer o que se costuma definir como inteligência. O cérebro e o sistema nervoso central têm o controle sobre o pensamento e o comportamento inteligente. As dificuldades de aprendizagem e de reação a estímulos daqueles que sofrem danos cerebrais exemplificam esse fato.

Podemos dividir um neurônio em núcleo, dendritos, que trazem as entradas (inputs) à célula, e axônio, que enviam sinais, as saídas (outputs), via seus terminais ao neurônio seguinte na rede. Os sinais podem ser transmitidos sem alteração ou através de sinapses. As sinapses possuem a propriedade de aumentar ou diminuir seu grau de conexão e, assim, causar excitação ou inibição de um neurônio subsequente.

## **Redes Neurais Artificiais**

Um modelo que simula uma Rede Neural biológica é uma Rede Neural artificial. A computação neural de hoje usa uma lista bastante limitada de conceitos inspirados no conhecimento atual de sistemas neurais biológicos. Os conceitos são usados na implementação de software de simulação de processos paralelos envolvendo elementos processadores (também chamados neurônios artificiais ou neurodes) interconectados através de uma arquitetura de rede. O neurônio artificial é análogo ao neurônio biológico : ele recebe entradas (inputs) como os impulsos eletroquímicos que os dendritos de neurônios biológicos recebem de outros neurônios; as saídas (outputs) dos neurônios artificiais correspondem aos sinais enviados através do axônio por um neurônio biológico; e, como nas sinapses, os sinais podem ser alterados.

Apesar da extensa pesquisa em neurobiologia e psicologia, restam ainda muitos mistérios sobre como a mente e o cérebro trabalham. A computação neural, no entanto, não está limitada aos avanços do entendimento biológico de Redes Neurais. Assim, apesar dos modelos de computação se distanciarem de sistemas biológicos e estarmos longe de uma máquina artificial como o cérebro, temos assistido a produção de sistemas bastante úteis e interessantes.

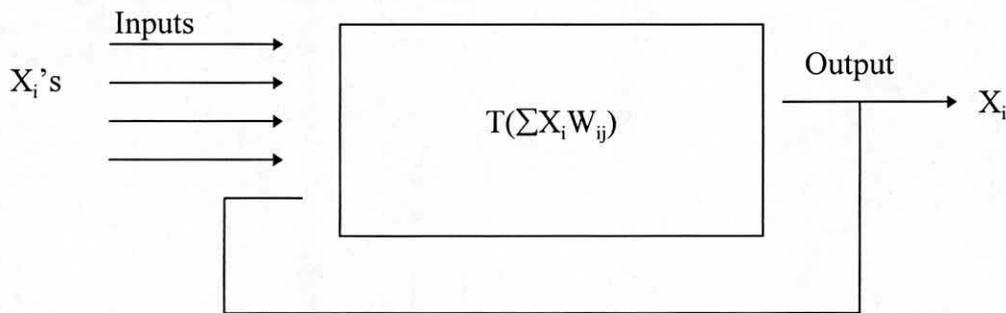
## Estruturas e Componentes de Redes Neurais

Uma rede é formada de elementos processadores que podem ser organizados de diversos modos e arquiteturas.

### Elementos Processadores

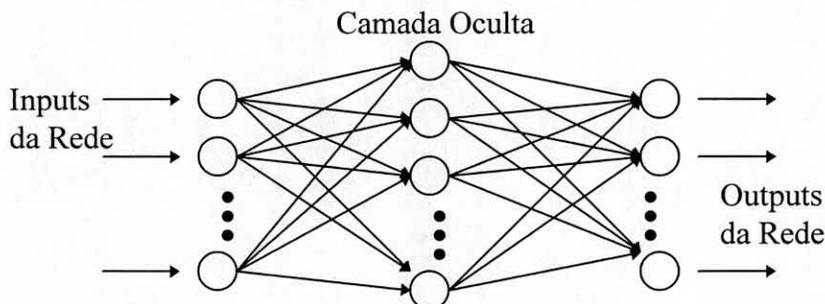
Os neurônios artificiais que compõem uma Rede Neural Artificial (RNA) são os elementos processadores (EP). Cada um desses neurônios recebe inputs, processa-os e envia outputs. O input pode ser um dado sem prévio processamento ou o output de outro elemento processador. O output pode ser o produto final ou o input de outro neurônio.

Esquema de um elemento processador neural:



### Rede

Cada RNA é composta de uma coleção de neurônios agrupados em camadas. Uma RNA simples com três camadas teria as camadas input, intermediária (camada oculta) e output. Esquema de uma Rede com três camadas:



## **Estrutura de Rede**

Como Rede Neurais biológicas uma RNA pode ser organizada de muitas maneiras diferentes (diversas topologias), ou seja, os neurônios podem estar conectados de modos diversos. Portanto, a RNA pode surgir com várias formas. No processamento da informação muitos dos elementos processadores fazem suas computações de maneira simultânea. Este processamento paralelo é similar ao modo como o cérebro trabalha e contrasta com o processamento serial da computação convencional.

## **Processando Informação na Rede**

Depois de estabelecida a estrutura da rede pode-se processar a informação relevante. Os elementos fundamentais neste processamento são : inputs, outputs e os pesos.

Inputs : cada input corresponde a um único atributo cujo valor é o input da rede. Os dados de input são numéricos, porém podem representar dados qualitativos como sim, não, etc.

Outputs : o output da rede é a solução de um problema. Por exemplo, no caso de uma abertura de crédito ele pode ser sim ou não. A RNA atribui valores numéricos com 1 para sim e 0 para não. O propósito da rede é computar o valor da saída.

Pesos : Elementos chave numa RNA, os pesos expressam a força relativa (ou o valor matemático) dos dados de entrada iniciais ou das várias conexões que transferem informação de um nível para outro da rede. Assim, os pesos expressam a importância relativa de cada entrada para um elemento processador. Pesos são cruciais já que é através de repetidos ajustes dos pesos que a rede “aprende”.

## Função somatória

A função somatória acha a média ponderada de todos os elementos de entrada para cada elemento processador. Uma função somatória multiplica os valores dos inputs (Xs) pelos pesos (Ws) e totaliza-os para uma soma ponderada, Y. Para N inputs i em um elemento processador j, temos :

$$Y_j = \sum_{i=1}^n X_i W_{ij}$$

## Função de Transformação ( Transferência)

A função somatória computa o estímulo interno, ou o nível de atividade, do neurônio (às vezes ela também é chamada de função de ativação). Baseado neste nível o neurônio pode ou não produzir um *output*. A relação entre a atividade interna e a saída pode ser linear ou não-linear. Tais relações são expressas por uma função de transformação (transferência) que se apresentam de diversas maneiras. A seleção de uma função específica determina a operação da rede. Uma função de transferência bastante popular é :

$$Y_T = \frac{1}{1 + e^{-y}}$$

onde  $Y_T$  é o valor transformado (ou normalizado) de Y.

O propósito dessa transformação é modificar os níveis das saídas para valores razoáveis (entre zero e um). Esta transformação é feita antes que o *output* atinja a próxima camada da rede. Sem esta transformação o valor pode ser muito grande, especialmente quando várias camadas estão envolvidas. Pode-se usar também, ao invés de uma função contínua de transformação, um detetor de entrada. Desse modo, cada valor igual ou menor

que 0.5 (ou outro número fixo) é alterado para zero, qualquer valor acima de 0.5 é alterado para um. Uma transformação pode ocorrer na saída de cada elemento processador ou pode ser efetuada no *output* final da rede.

## **Aprendizagem**

Uma RNA aprende com seus erros. O processo usual de aprendizagem (ou treinamento) envolve três etapas : computar as saídas; comparar as saídas com as respostas desejadas; e ajustar os pesos e repetir o processo.

O processo de aprendizagem geralmente começa com uma seleção de pesos randômica. A diferença entre o *output* ( $Y$  ou  $Y_T$ ) e o *output* desejado ( $Z$ ) é chamado  $\Delta$ . O objetivo é minimizar  $\Delta$  (ou melhor, reduzi-lo a zero). A redução de  $\Delta$  é feita através da modificação incremental dos pesos.

O processamento de informação com RNA consiste da análise de atividades de padrões (reconhecimento de padrões) com informação aprendida e guardada como os pesos de conexão entre os neurônios. Uma característica comum dos sistemas é a habilidade de classificar séries de dados de entrada sem o conhecimento explícito de regras e de usar padrões arbitrários de pesos para representar a memória de categorias. Durante os estágios de aprendizagem, os pesos de interconexão mudam de acordo com os estímulos dados pelas informações de treinamento apresentadas ao sistema. Diferentes RNAs computam o erro de modos diversos dependendo do algoritmo de aprendizagem utilizado. Mais de cem algoritmos estão disponíveis para várias situações e configurações. No treinamento de uma rede as informações de treinamento são divididas em duas categorias: casos de teste e casos de treinamento.

## Virtudes e Fraquezas de uma RNA

A tecnologia de Rede Neural tem vantagens significativas sobre uma regra convencional - ou aproximações através de sistemas especialistas baseados em estrutura fixa - em algumas aplicações. Primeiramente, como Redes Neurais não requerem conhecimento formal elas são apropriadas para domínios onde o conhecimento é escasso. Sistemas especialistas convencionais mapeam as respostas aos *inputs* em espaços progressivamente refinados porém linearmente separáveis. Redes Neurais, por outro lado, podem desenvolver fronteiras entre entradas e saídas que são altamente não-lineares. Alguns tipos de problema se beneficiam deste tipo de capacidade. Além disso, mesmo que sistemas especialistas permitam que probabilidades de classificação sejam incorporadas em regras, normalmente elas precisam ser explicitamente definidas. Alguns tipos de Redes Neurais são capazes de deduzir estas probabilidades através do treinamento. É difícil para sistemas especialistas baseados em regras desenvolver regras a partir de dados históricos quando as entradas são altamente correlacionadas. Os paradigmas de aprendizagem de Redes Neurais não sofrem deste problema. Finalmente, o tempo de processamento por caso de uma Rede Neural pode ser menor do que o de sistemas convencionais já que a rede examina toda a informação disponível sobre um problema de uma vez. Isso facilita uma interface de entrada mais automatizada.

As Redes Neurais têm outros benefícios: tolerância a defeitos, como existem muitos elementos processadores, cada um com conexões primariamente locais, danos a alguns elementos ou conexões não causa a parada de todo o sistema; generalização, quando se apresenta à uma Rede Neural uma entrada com ruídos, incompleta ou inédita ela gera uma resposta razoável; e adaptação, como a rede aprende em novos ambientes o treinamento pode ocorrer continuamente durante sua vida útil e ocorrer de maneira concorrente à inicialização da rede.

As Redes Neurais têm suas fraquezas, nem todas as aplicações potenciais de sistemas especialistas se beneficiam das vantagens de Redes Neurais ou compensam os

custos adicionais e a complexidade. Uma característica, às vezes, inaceitável de Redes Neurais é o fato delas classificarem como relevantes para a tomada de decisão fatores que aparentemente são irrelevantes ou mesmo fatores que conflitam com as teorias tradicionais de domínio público. Como a abrangência do treinamento é sempre limitada em algum grau por economia e tempo, redes que contradizem teorias comumente aceitas correm o risco de não possuir características generalistas, funcionando bem apenas com dados de estrutura similar àquela dos dados de treinamento.

A maioria dos sistemas de Redes Neurais não possuem facilidades de explicação. Justificativas para os resultados são difíceis de se obter porque os pesos de conexão geralmente não têm interpretações óbvias. Isso se torna ainda mais evidente no reconhecimento de padrões onde é muito difícil ou praticamente impossível de se explicar a lógica por trás de decisões específicas. Com a tecnologia atual, os períodos de treinamento podem ser grandes e tediosos, assim, a necessidade de retreinamento frequente pode tornar uma aplicação impraticável. O melhor modo de se representar dados de entrada e a escolha de arquitetura é ainda , em sua maior parte sujeita à tentativa e erro. A computação neural usualmente requer grandes quantidades de dados e longos períodos de treinamento.

Além disso, a maioria dos sistemas neurais não podem garantir uma solução ótima para um problema, uma solução completamente certa, ou mesmo, em alguns casos, repetição de resultados com os mesmos dados de entrada. Entretanto, redes neurais apropriadamente configuradas e treinadas podem fazer com frequência classificações, generalizações, ou decisões consistentes num sentido estatístico.

Redes Neurais podem ser usadas de maneira eficiente para automatizar ambas as tarefas de análise financeira rotineiras e as customizadas. Protótipos de sistemas de auxílio à decisão baseados em Redes Neurais foram construídos para as seguintes aplicações : seleção para autorização de crédito; classificação do risco de hipotecas; administração de projetos e estratégia de compras; previsão financeira e econômica; classificação de risco de

investimentos em renda fixa e de investimentos em bolsa; detecção de regularidades em movimentos dos preços de títulos; predição de insolvência e falência.

Outras aplicações potenciais merecedoras de pesquisa posterior, desenvolvimento e avaliação são as seguintes : seleção e diversificação de portfolios; simulação de comportamentos do mercado; construção de índices; identificação de fatores econômicos explicativos; “mineração” de bancos de dados financeiros e econômicos.

## Desenvolvimento de Aplicações em Redes Neurais

Aplicações em Redes Neurais já são suficientes para se identificar regras que delineiem seu desenvolvimento. Os primeiros dois passos no processo de desenvolvimento de uma RNA envolvem a coleta de dados e a separação deles em um conjunto de treinamento e um conjunto de teste. Essas tarefas precisam ser baseadas em uma análise rigorosa da aplicação para que o problema seja bem definido e a funcionalidade do sistema e o contexto de Redes Neurais sejam bem entendidos.

Em conjunto com um especialista da área, o desenvolvedor precisa identificar e esclarecer as informações relevantes ao problema. Isso significa formular e conceituar a tarefa de uma maneira orientada ao processamento de dados para que o problema seja acessível a uma solução em rede. Por exemplo, descrições em texto precisam ser reformuladas para possibilitar que o conhecimento seja descrito numericamente. O desenvolvedor precisa evitar desvios causados por uma representação específica das informações. Outras considerações são a estabilidade das entradas e a que grau as condições ambientais podem requerer mudanças no número de nós de entrada para a Rede Neural. Nesta etapa, uma dificuldade em expressar a informação da forma necessária para uma Rede Neural pode levar ao cancelamento do projeto.

A estrutura antecipada da Rede Neural e o algoritmo de aprendizagem determinam o tipo de dados, por exemplo binário ou contínuo. Um banco de dados de alta qualidade necessita de cuidados para se minimizar ambiguidade, erros e aleatoriedades nas informações. As informações devem ser coletadas para cobrir a maior parte do domínio do problema, elas devem cobrir não apenas operações de rotina, mas também exceções e condições na fronteira do domínio do problema. Outra tarefa é confirmar a confiabilidade do conjunto de dados utilizando-se de múltiplas fontes de informação, mesmo assim, ambiguidades devem ser resolvidas. De modo geral, quanto mais informação se usa, melhor - desde que não se sacrifique a qualidade. Maiores conjuntos de dados aumentam o tempo de processamento durante o treinamento, mas informações melhores aumentam a acurácia

do treinamento e podem levar a uma convergência mais rápida para um bom conjunto de pesos.

Normalmente o treinamento de uma Rede Neural começa com a separação de dados. Os conjuntos de informação são classificados em duas categorias : casos de treinamento e casos de teste. Os casos de treinamento são usados para ajustar os pesos. Os casos de teste são usados na validação da rede. O número de casos necessários para cada categoria pode ser computado através da consideração de vários fatores (Butler e Caudill, 1990 e Khanna, 1990).

## **Estruturas de Rede**

Muitos modelos diferentes de Redes Neurais e implementações estão sendo estudadas e desenvolvidas (Hecht-Nielson, 1990 e Beale e Jackson, 1990). A seguir, discutiremos três arquiteturas representativas :

## **Sistemas de Memória Associativa**

Memória associativa é a habilidade de recuperar situações completas através de informação parcial. Estes sistemas correlacionam dados de entrada com informação gravada na memória. Informação pode ser recuperada de *inputs* com ruído ou incompletos e a performance cai vagarosamente, a medida em que os neurônios falham. Sistemas de memória associativa podem detectar similaridades entre padrões de novos *inputs* e de dados guardados. A maioria das arquiteturas de Redes Neurais podem ser usadas como memórias associativas e um exemplo de um sistema de camada única é a rede de Hopfield, que utiliza as propriedades de consolidação e minimização de uma função de energia para classificar padrões de entradas.

## **Camada Oculta**

Sistemas de memória associativa podem ter uma ou mais camadas intermediárias (ocultas). Muitas das redes que se utilizam de multiníveis usam o algoritmo de aprendizagem de propagação reversa. Outro tipo de aprendizagem sem supervisão, o filtro competitivo de memória associativa, é capaz de aprender mudando os pesos no reconhecimento de categorias de dados de entrada sem que exemplos tenham sido providenciados por um treinador externo (Kohonen, 1984).

## **Estrutura de Dupla Camada**

Uma estrutura de dupla camada, exemplificada através da Teoria da Ressonância Adaptativa, não exige o conhecimento de um número preciso de classes nos dados de treinamento (Carpenter e Grossberg, 1987). Ao contrário ela usa o sistema de alimentação para frente e alimentação para trás para ajustar os parâmetros, enquanto a informação é analisada para se estabelecer números arbitrários de categorias que representem os dados apresentados ao sistema. Parâmetros podem ser ajustados para sintonizar a sensibilidade do sistema e produzir categorias que façam sentido.

Para aplicações mais complexas de computações neurais, os neurônios são combinados em diversas arquiteturas úteis para o processamento de informação. Aplicações práticas exigem uma ou mais camadas (ocultas) entre os neurônios de entrada e os de saída e, conseqüentemente, um grande número de pesos.

## Algoritmos de Aprendizagem

Uma consideração importante em uma RNA é o uso apropriado de algoritmos para aprendizagem (ou treinamento). Tais algoritmos são chamados de algoritmos de aprendizagem (ou paradigmas) e são conhecidos centenas deles. Uma taxonomia de tais algoritmos foi proposta por Lippman que distingue entre duas categorias principais baseadas no formato de dados de entrada : dados de entrada de valores binários (0 e 1) ou dados de entrada de valores contínuos. Cada uma dessas categorias pode ser então dividida em duas categorias básicas : aprendizagem supervisionada e aprendizagem sem supervisão.

A aprendizagem supervisionada utiliza-se de um conjunto de *inputs* para os quais os *outputs* desejados são conhecidos. Em um tipo as diferenças entre as saídas desejadas e projetadas são usadas para se calcular as correções nos pesos da Rede Neural. Uma variação dessa aproximação simplesmente reconhece cada tentativa de entrada e guarda se as saídas foram corretas ou não, enquanto a rede ajusta os pesos procurando atingir os resultados corretos. Exemplos deste tipo de aprendizagem são a propagação reversa e a rede de Hopfield.

Na aprendizagem sem supervisão somente estímulos de entrada são apresentados à rede. A rede se auto-organiza, ou seja, ela se organiza internamente para que cada elemento processador oculto (intermediário) responda estrategicamente a um conjunto diferente de estímulos de entrada (ou grupos de estímulo). Nenhum conhecimento é fornecido sobre quais classificações (saídas) são corretas e àquelas derivadas pela rede podem ou não ter significado para a pessoa treinando a rede. Entretanto, o número de categorias em que uma rede classifica os *inputs* pode ser controlado através da variação de certos parâmetros no modelo. Em todo caso, um humano precisa examinar as categorias finais para dar sentido e determinar a utilidade dos resultados. Exemplos desse tipo de aprendizagem são a Teoria da Ressonância Adaptativa e os mapas auto-organizáveis de Kohonen.

## Como uma Rede Aprende

Consideremos um único neurônio que recebe dois *inputs*, X1 e X2. Se qualquer uma ou ambas as entradas forem positivas o resultado desejado é positivo. Se imaginarmos que os *inputs* são representados, no caso, através de zeros e uns, cada vez que uma das entradas ou as duas forem iguais a um a Rede deve classificá-las para uma saída igual a um.

O neurônio precisa ser treinado para reconhecer os padrões das entradas e classificá-los dando-lhes as saídas correspondentes. O procedimento ocorre com a apresentação ao neurônio da sequência dos quatro tipos possíveis, no exemplo, de padrões de dados de entrada. Através dessa sequência o computador ajusta os pesos após cada iteração. Essa operação se repete até que os pesos convirjam para um conjunto de valores que possibilite ao neurônio classificar corretamente todos os quatro tipos de combinações dos dados de entrada.

Após calcularmos os *outputs* da primeira iteração, uma medida de desvio ( $\Delta$ ) entre as saídas computadas e os valores desejados é usada para se atualizar os pesos subsequentemente, procurando resultados corretos. Em qualquer iteração, o processo para um neurônio  $j$ , se dá através de :

$$\Delta = Z_j - Y_j$$

onde, Z e Y são, respectivamente, o valor desejado e o valor computado das saídas. Os pesos atualizados são dados por :

$$W_i(\text{ Final}) = W_i(\text{ Inicial}) + \alpha\Delta X_i$$

onde  $\alpha$  é o parâmetro que controla a rapidez da aprendizagem.

No desenvolvimento de RNA é feita uma tentativa de se adequar as características de um problema a um dos algoritmos de aprendizagem conhecidos. Existem softwares para

todos os algoritmos mais comuns, mas se têm mais segurança usando um algoritmo bem estudado e caracterizado como o de propagação reversa.

## Treinando a Rede

Esta fase consiste na apresentação do conjunto de informação de treinamento para à rede, para que os pesos possam ser ajustados, para a produção das saídas desejadas para cada um dos tipos de dados de entrada. Os pesos são ajustados após cada vetor de entrada é apresentado, assim, são necessárias inúmeras iterações do conjunto de dados completo até que um conjunto de pesos consistente que funcione para toda a informação de treinamento seja derivado pela rede.

A escolha da estrutura da rede, ou seja, o número de neurônios e camadas, bem como a seleção da condição inicial da mesma, determinam o tempo de treinamento. Portanto, tais decisões são importantes e requerem muita atenção e cuidado logo no início do processo.

No caso ideal, a rede consegue aprender as características dos dados de entrada sem aprender detalhes irrelevantes. Desse modo, com a apresentação de novos *inputs* que não sejam idênticos àqueles do conjunto de treinamento, a rede seria capaz de fazer as classificações corretas.

No primeiro passo do processo de desenvolvimento, os dados disponíveis são divididos em conjuntos de treinamento e teste. Após o treinamento ter sido feito, é necessário se testar a rede. A fase de testes examina a performance da rede usando os pesos derivados através da medição da habilidade da rede de classificar os dados de teste corretamente. O teste de caixa preta (black-box testing), isto é, a comparação dos resultados dos testes com resultados históricos reais, é a principal maneira de se verificar se as entradas estão produzindo as saídas apropriadas.

Em muitos casos não se espera que a rede funcione perfeitamente e se exige apenas um certo nível de qualidade. Geralmente, uma aplicação em Rede Neural é uma alternativa a um outro método qualquer que é usado como padrão. Suponhamos, por exemplo, que uma

técnica estatística ou outro método quantitativo qualquer consegue classificar dados corretamente 70% das vezes, a implementação de uma Rede Neural, muitas vezes, melhora esse percentual. Se a Rede Neural está substituindo operações manuais, níveis de performance de processamento humano podem ser o padrão para a decidir se a fase de testes foi ou não bem sucedida.

O plano de teste deve incluir casos rotineiros e também situações potencialmente problemáticas, como, por exemplo, situações nos limites do domínio do problema. Se os teste revelarem grandes desvios, o conjunto de treinamento precisa ser reexaminado e o processo de treinamento talvez tenha de ser reativado.

Em alguns casos, outros métodos podem complementar teste de caixa preta puros. Pode-se, por exemplo, analisar estatisticamente os pesos para se procurar por valores estranhamente grandes que indiquem excesso de treinamento ou valores estranhamente pequenos que indiquem neurônios desnecessários e que possam ser eliminados. Além disso, certos pesos que representem fatores preponderantes no vetor de entrada podem ser ativados seletivamente para se ter certeza de que as saídas correspondentes respondam apropriadamente.

Mesmo num nível de performance igual a de um método tradicional, uma RNA pode ter outras vantagens. A rede é facilmente modificada através de retreinamento com novos dados. Outras técnicas computadorizadas podem exigir reprogramação extensa quando são necessárias mudanças.

## Implementação

A implementação de uma RNA frequentemente requer interfaces apropriadas para outros sistemas de informação baseados em computador e o treinamento de usuários. Monitoração contínua e *feedback* aos desenvolvedores são recomendados para melhorias no sistema e sucesso de longo prazo. Uma consideração importante é ganhar a confiança dos usuários e da gerência no começo da instalação para se assegurar que o sistema seja aceito e usado corretamente.

Se ela é parte de um sistema maior, a RNA vai necessitar de interfaces convenientes para outros sistemas de informação, dispositivos de entrada e saída, e operações manuais dos usuários. Este sistema pode precisar de manipulação de subsistemas de entrada e saída como digitalizadores de sinal e módulos de conversão de arquivos. Boa documentação e treinamento do usuário são necessários para garantir uma integração bem sucedida na rede principal das operações. Um procedimento conveniente precisa ser planejado para a atualização dos conjuntos de treinamento e para a iniciação de retreinamento periódico da rede. Isto inclui a capacidade de reconhecer e introduzir novos casos que são descobertos quando o sistema é usado rotineiramente.

Monitoração contínua e resposta aos desenvolvedores são necessários para a manutenção dos sistemas de rede neural. A avaliação periódica da performance do sistema pode revelar mudanças ambientais ou defeitos previamente não detectados que exijam alterações na rede. Melhoramentos podem ser sugeridos na medida em que os usuários se tornem mais familiarizados com o sistema e o *feedback* pode ser útil para o desenho de futuras versões ou em novos produtos.

## **Sobre os paradigmas da computação neural**

Na construção de uma Rede Neural Artificial, o construtor precisa tomar várias decisões. As mais importantes giram em torno dos seguintes assuntos : tamanho dos conjuntos de treinamento e teste; algoritmos de aprendizagem; topologia, número de elementos processadores e sua configuração (entradas, camadas, saídas); função de transformação (transferência) a ser usada; velocidade de aprendizagem de cada camada; e seleção de ferramentas de validação e diagnóstico.

Uma coleção específica de configurações determinada por estas decisões é chamada de paradigma da rede.

## Programando Redes Neurais

Redes Neurais Artificiais são basicamente aplicativos de software que precisam ser programados. Como qualquer outro aplicativo, uma RNA pode ser programada em uma linguagem de programação, através de uma ferramenta ou através de ambos.

Grande parte da programação lida com os algoritmos de aprendizagem e as funções somatória e de transferência. Logo, faz sentido o uso de ferramentas de desenvolvimento nas quais estas computações padronizadas são pré-programadas e, com efeito, diversas ferramentas de desenvolvimento estão disponíveis no mercado. Mesmo com a ajuda de ferramentas de RNA, no entanto, o trabalho de se desenvolver uma rede neural pode não ser tão simples. Especificamente, pode-se ter que programar o desenho do banco de dados, a partição dos dados (treinamento e teste) e a transferência da informação para arquivos que sirvam como entrada para uma ferramenta de desenvolvimento de RNA.

A maioria das ferramentas de desenvolvimento suportam diversos tipos de paradigmas de rede. Além dos programas padrão, muitos programas especializados também estão disponíveis, por exemplo, produtos baseados em planilhas, outros produtos são ainda criados para trabalhar com sistemas especialistas como desenvolvedores de produtos híbridos.

O usuário dessas ferramentas está preso à configuração da mesma. Assim, construtores muitas vezes preferem usar linguagens de programação como C ou usar planilhas para programar o modelo e executar os cálculos.

## Hardware de Redes Neurais

A maioria dos aplicativos atuais de Redes Neurais envolve softwares de simulação que são executadas em processadores convencionais sequenciais. Simular uma rede neural significa matemática definir os neurônios e os pesos distribuídos a eles. Portanto, ao invés de se usar uma unidade de processamento central (UCP) para cada neurônio, uma UCP é usada para todos eles. Esta simulação pode exigir tempos de processamento longos. Avanços na tecnologia de hardware irão melhorar bastante a performance de futuros sistemas de redes neurais através da exploração da vantagem inerente do processamento paralelo em massa. Melhoramentos no hardware irão atingir as maiores exigências de memória e velocidade de processamento e, desse modo, possibilitarão treinamentos menores para redes maiores.

Cada elemento processador computa as saídas do neurônio com os pesos e sinais de entrada de outros processadores. Em conjunto, a rede de neurônios pode guardar informação que futuramente pode ser usada para interpretar e classificar novos *inputs* da rede.

Para reduzir o trabalho computacional de uma RNA que pode consistir em centenas de milhares de manipulações quando o trabalho é feito em computadores normais, uma das três aproximações é possível : máquinas mais rápidas, uma máquina complementada por um coprocessador matemático mais rápidos pode acelerar o trabalho; chips neurais, a maioria dos chips semicondutores de hoje pode executar computações muito rapidamente, mas eles não podem ser usados no treinamento da rede, assim, é necessário se treinar “fora do chip” (*off the chip*). Espera-se que logo este problema seja solucionado, no meio tempo, placas de aceleração podem ser úteis. A idéia é fazer a implementação de estruturas de dados de Redes Neurais através de hardware e não software, usando um dispositivo analógico ou digital ou mesmo ótico (Caudill – 1991). A maioria das redes implementadas através de hardware ainda estão na fase de desenvolvimento; e placas de aceleração, estas são dedicadas a processadores de chips múltiplos que possam ser adicionadas a

computadores normais, elas funcionam de maneira similar a um coprocessador matemático. Como são desenhados especialmente para uma RNA são muito rápidas para este aplicativo. Atualmente são a melhor saída para se acelerar computações. São extremamente úteis, pois reduzem o tempo de treinamento que geralmente é longo.

## Situação das Redes Neurais Artificiais

Redes Neurais artificiais representam uma forma radicalmente diferente de computação. A computação neural é maciçamente paralela e, normalmente, envolve de milhares a milhões de processamentos simples individuais, arranjados numa rede comunicativa. A tecnologia de RNA pode fornecer performance superior a aproximações convencionais de resolução de problemas numa grande variedade de áreas. Mesmo com numerosos modelos de redes neurais e produtos de apoio a esses modelos estejam, agora, disponíveis, a instalação de sistemas baseados em Redes Neurais para ajudar na tomada de decisão está ainda no seu início de desenvolvimento, com boa parte de sua atual atividade ocorrendo ainda num nível de pesquisa.

As capacidades únicas de aprendizagem de uma RNA prometem benefícios em muitos aspectos das tomadas de decisões de investimento e financeira que envolvam reconhecimento de padrões e nas quais a representação adequada do conhecimento seja difícil ou impossível. Aplicativos comerciais que provavelmente serão bem sucedidos são aqueles : que assistam diretamente profissionais da área de finanças em um ou mais aspectos específicos do seu trabalho, assim como a implementação de uma determinada estratégia; ou que forneçam resultados melhores do que métodos estatísticos ou outras formas convencionais de análise quando utilizados para operações mais rotineiras como análises de crédito e risco.

## Redes Neurais na análise de condição financeira

### Papel das Redes Neurais na análise de condição financeira

Vemos em Berry e Trigueiros a capacidade de Redes Neurais de gerar estruturas semelhantes a índices financeiros que são ótimas no contexto do problema sendo analisado. Isso faz com que não haja necessidade de um analista pesquisar quais os índices apropriados antes que a construção do modelo se inicie. A organização interna de uma Rede Neural ajuda a identificar pontos chave em demonstrações financeiras e possibilita novos pontos de vista sobre a importância relativa de variáveis em tarefas específicas de modelagem.

A dificuldade de interpretação dos resultados das Redes Neurais tantas vezes publicada e discutida não aparece no contexto contábil, pois grande parte da operação interna das Redes Neurais nessas aplicações envolve a generalização de conceitos de índices familiares aqueles que lidam com a análise de demonstrações financeiras e, assim, modos tradicionais de entendimento podem ser utilizados na interpretação da RNA.

Muitas razões explicam porque uma aproximação através de RNA pode produzir resultados superiores à aproximações baseadas em regressão na análise de dados financeiros. RNAs são capazes de reconhecer padrões em contas mesmo quando os dados têm ruídos, são ambíguos, distorcidos, ou variáveis. RNAs mantêm uma boa performance mesmo com dados incompletos - uma tarefa extremamente difícil para regressões. Além disso, uma RNA é capaz de descobrir relacionamentos entre os dados, enquanto que a construção de um modelo baseado em regressão presume conhecimento prévio das relações entre os dados. Como a RNA incorpora essas relações, os *outputs* gerados não são sensíveis a variações insignificantes nos padrões de entrada, como demonstrado por Hecht-Nielsen em 1989.

Ainda segundo Hecht-Nielsen, a vantagem principal de Redes Neurais sobre uma análise de regressão clássica é que as RNAs têm formas funcionais mais gerais do que outros métodos estatísticos mais explorados. Isso porque RNAs não dependem de superposição linear e funções ortogonais, que aplicações de regressão linear estatística precisam utilizar. Logo, as aproximações que surgem de RNAs propriamente aplicadas são geralmente melhores que as funções obtidas pelas técnicas de regressão. Essa diferença é especialmente importante em espaços com muitas dimensões nos quais técnicas regressivas muitas vezes falham em fornecer uma aproximação válida para a modelagem do ambiente. Fornecer um grande número de parâmetros de entrada para uma RNA não representa um problema estrutural do modelo como na regressão. Quando a variável não for importante para a resolução do problema, a RNA irá aprender a ignorar esse parâmetro designando valores próximos de zero para a ponderação desses dados.

## Exemplos da utilização de Redes Neurais na análise de condição financeira

### Creditview

Um estudo sobre uma Rede Neural híbrida baseada em estatística utilizada pelo Chase Manhattan Bank nos é trazido por Marose. O objetivo fundamental da RNA é reduzir perdas em empréstimos feitos à empresas públicas e privadas. Muitos dos produtos do Chase para empresas envolvem a definição da qualidade de crédito dos clientes. Em 1985, o Chase começou uma busca por novas técnicas quantitativas que auxiliassem os analistas na previsão de insolvência de empresas candidatas a novos empréstimos.

O modelo resultante desses esforços concentrados pela Inductive Inference Inc. Foi chamado de Creditview system. Ele realiza previsões de três anos que indicam com uma companhia deve ser posicionada segundo a classificação de risco do Chase de good, criticized e charged-off. Além dessa previsão, o Creditview gera uma lista delhada dos itens que contribuíram significativamente para a previsão, uma interpretação desses itens gerada por um sistema especialista e diversos relatórios comparativos.

O usuário é beneficiado pelo sistema, pois ele identifica os pontos fortes e fracos na estrutura financeira do devedor e prevê o impacto desses fatores sobre a saúde financeira da firma três anos no futuro. O Chase testou o sistema exaustivamente e tendo identificado muitos dos potencialmente problemáticos empréstimos passou a implementá-lo.

Do ponto de vista de um estatístico há uma diferença importante entre o sistema e as Redes neurais clássicas. Essa distinção é que Redes Neurais maximizam a acuracidade na classificação de dados históricos, o sistema, entretanto, maximiza a acuracidade da classificação após descontar um viés.

Estudos já vêm sendo desenvolvidos em cima dessa tecnologia e comprovado seu uso em outros campos como planejamento empresarial, análise de investimento de portfólio e modelos de exploração de petróleo.

### **Análise de índices no processo de revisão analítica e Redes Neurais**

Esse estudo desenvolvido por Brown e Coakley objetivava identificar novas aproximações para a revisão analítica de uma auditoria e que criassem procedimentos diretos aplicáveis a uma grande variedade de organizações e indústrias. A pergunta proposta inicialmente foi se uma RNA produziria sinais de investigação mais apropriados para os dados flutuantes que normalmente formam as demonstrações financeiras.

Como características da Rede Neural desenvolvida temos como algoritmo de treinamento um modelo de *back-propagation*, como arquitetura de modelo de rede uma arquitetura *feedforward* de múltiplas camadas e como função de transferência ou regra de ativação do modelo foi escolhida uma função senóide modificada.

Os resultados obtidos com a RNA foram comparados com os resultados obtidos através de uma regressão e com os resultados de uma análise feita através de índices financeiros. O estudo mostra que a aproximação através de RNAs trouxe maior confiabilidade, mas menor eficiência, isto é, a RNA classificou como suspeitas e merecedoras de investigação o maior número de contas, assim, ela acertou o maior número de contas que mereciam ser investigadas, porém também colocou muitas contas para serem investigadas que não mereciam esse tratamento.

Quando faz-se uma média entre os indicadores de confiabilidade e de eficiência a RNA é ligeiramente mais eficaz que os outros métodos. Entretanto, nenhum desses procedimentos oferece melhorias significativas sobre um processo puramente aleatório, o que reforça os resultados encontrados por Loebbecke e Steinbart em 1987.

## Reconhecimento de padrões de dificuldade financeira

O modo tradicional de se prever dificuldades financeiras se utiliza da análise discriminante múltipla para ponderar o valor relativo da informação fornecida por uma combinação de índices financeiros. Esse modelo, entretanto, carrega algumas restrições. Uma delas é que a análise múltipla discriminante requer que os dados utilizados para se distinguir entre firmas com problemas e saudáveis sejam linearmente separáveis, isto é, para um único índice isso significa que um valor acima ou abaixo do ponto de decisão sempre sinalizará ou dificuldades ou saúde financeira. Outra restrição altamente problemática para a análise múltipla discriminante é que ela não deixa um índice variar dependendo de sua relação com outro índice ou conjunto de índices, ou seja, os índices são tratados de maneira completamente independente. Esses problemas e outros como viés em ponto extremos, pressuposto da normalidade múltipla e pressuposto de covariâncias iguais para o grupo motivam essa pesquisa a procurar um método alternativo à análise múltipla discriminante.

Opta-se pela RNA como ferramenta, pois ela pode utilizar os mesmo índices da análise múltipla discriminante para o mesmo objetivo sem nenhuma das restrições que limitam o método anterior. O estudo formula a seguinte questão: com quanto sucesso podem as Redes Neurais discernir padrões ou tendências em dados financeiros e classificá-los como sinais de dificuldades financeiras em firmas atualmente saudáveis?

O resultado do teste mostrou que a RNA é mais eficaz que a análise múltipla discriminante na classificação de padrões. A RNA mantém uma confiabilidade maior do que a análise múltipla discriminante em todos os períodos de análise.

## Redes Neurais na previsão de falências

A análise de índices tem sido a base de toda a predição de falências até hoje. Mckinley nos diz que índices são as mais conhecidas e utilizadas das ferramentas financeiras. Segundo Miller, alguns índices representam causa e outros representam consequência. As técnicas estatísticas que mostram os índices como determinantes válidos de firmas fadadas à falência e empresas destinadas à sobrevivência apóiam o uso de análises discriminantes na resolução desse tipo de problema que, normalmente, é visto como um problema de classificação.

### Previsão de falência através de uma Rede Neural

Esse estudo baseia-se tanto no estudo pioneiro de Altman sobre previsão de falências através de análise discriminante multivariada, além do estudo comparativo feito por Odom e Sharda entre três paradigmas de computação neural. O estudo se utilizou da mesma base de dados do estudo de Odom e Sarda e das mesmas variáveis (índices financeiros) utilizadas por Altman. Foram utilizados, então três paradigmas neste estudo: *back propagation*, *athena* e *perceptron*.

A análise discriminante assume alguns pressupostos que restringem seu uso, como a distribuição das variáveis discriminantes, as Redes Neurais não estão sob tais exigências, logo, quando elas produzem resultados com eficiência comparável elas são mais seguras. Além disso, há uma relação muito próxima entre análise discriminante múltipla e o método de regressão com variável dependente binária (*variáveis dummy*) e muitos pressupostos como a normalidade dos erros ou a homocedasticidade das variâncias não são satisfeitos por índices financeiros do mundo real utilizados em análise discriminante.

O paradigma de *back propagation* é uma Rede Neural de múltiplas camadas que utiliza a função sigmoideal como função de ativação. Este paradigma se utiliza de

aprendizado supervisionado. O paradigma *athena* é uma Rede Neural para a classificação de padrões que utiliza como base uma medida de entropia e aprendizado supervisionado. O modelo se utiliza de hiperplanos na divisão do espaço em conjuntos convexos que contêm objetos da mesma classe. O paradigma *perceptron* é uma Rede Neural de única camada com resultados binários e treinamento supervisionado.

Os resultados dessa análise apontaram que o problema de falência formulado é potencialmente separável linearmente. A melhor performance foi obtida através do paradigma *athena* que obteve a mesma acuracidade dos outros modelos utilizando um tempo de processamento menor.

### **Previsão de falências: uma comparação com análise discriminante**

O maior propósito deste estudo era a comparação entre análise discriminante e Redes Neurais. A base de dados foi constituída por três anos de demonstrações financeiras de 300 empresas francesas, das quais metade foi à falência. Utilizou-se um *perceptron* de múltipla camada, ou uma rede de *back propagation*.

Os resultados deste estudo evidenciaram mais uma vez a boa adaptação das Redes Neurais à tarefa de previsão de falências, além de indicar que as Redes Neurais apresentam uma melhor performance do que análise discriminante tradicional nesta área. Entretanto, não são todos os tipos de Redes Neurais que funcionam melhor do que a análise discriminante, o *perceptron* de múltipla camada ou rede de *back propagation* parece ser o mais indicado para a previsão de falências.

## **Redes Neurais e o risco de dívidas**

As aplicações de Redes Neurais podem ser divididas em duas amplas categorias: reconhecimento e generalização. Reconhecimento de formas e geração de voz são exemplos de problemas de reconhecimento, enquanto que exemplos típicos de generalização são problemas de classificação e previsão. Os problemas de generalização podem ser ainda subdivididos de acordo com o domínio de onde a aplicação de Redes Neurais irá atuar. Esse domínio pode ser tem um modelo bem definido, ou uma teoria parcialmente definida, ou não ter um modelo, teoria ainda desenvolvidos. As Redes Neurais são particularmente úteis nos domínios que não têm ainda teoria e modelos bem definidos, pois elas não exigem especificações antecipadas, ao contrário ela tenta aprender o modelo do domínio através dos exemplos de entrada e saída. O domínio do risco de dívidas, particularmente a classificação de títulos (*bond rating*), é uma área de alta importância no mundo das finanças e que não apresenta um modelo bem definido.

### **Classificação de títulos: uma aplicação não-conservadora de Redes Neurais**

O risco de não pagamento de um título é classificado por diversas empresas independentes como Standard and Poor's e Moody's. Na avaliação do risco dos títulos são levados em conta diversos aspectos da empresa emissora como capacidade de pagamento, intenção de pagamento e provisões protetoras de pagamento para uma emissão específica. Não é possível definir precisamente um modelo matemático que faça a classificação dos títulos como as agências o fazem, pois, por exemplo, não se sabem todos os aspectos analisados pelo comitê de rating e mesmo alguns aspectos conhecidos como a intenção de pagamento são afetados por uma grande quantidade de variáveis que são difíceis identificar.

Assim, como é importante se desenvolver um modelo de classificação de títulos para que um instituição financeira possa avaliar independentemente o risco de não

pagamento de seus investimentos em títulos propõe-se a utilização de uma Rede Neural para a tarefa.

Empregou-se uma Rede de múltipla camada, 10 variáveis financeiras baseadas nos resultados de Horrigan e Pinches e Mingo, 30 classificações de títulos escolhidas aleatoriamente foram utilizadas como dados de treinamento e outras 17 como dados de teste para a Rede Neural e para um modelo de regressão linear desenvolvido como base de comparação.

Percebeu-se que as Redes Neurais sempre apresentavam performance superior à da regressão, demonstrando que não estão limitadas a problemas de reconhecimento, mas também são especialmente úteis em problemas de generalização nos quais o conhecimento formal é escasso, domínios não-conservadores.

### **Classificação de Títulos com Redes Neurais**

Este trabalho fala das tentativas de se classificar títulos através de Redes Neurais e do fato disso significar uma ampliação da capacidade reconhecida de Redes Neurais. Normalmente, aceita-se a grande habilidade das Redes Neurais em decodificar ou reconhecer padrões, seu uso nesta área, entretanto, parece assumir que elas têm também a capacidade de mimetizar uma lógica indutiva. É apresentado um estudo no qual se buscou prever se haveria mudanças de classificação nos títulos e qual seria essa mudança.

Finaliza-se com a idéia de que as Redes neurais demonstraram sua capacidade de reconhecer padrões em séries econômicas complexas, além de terem demonstrado sua capacidade de captar parte do julgamento exercido por analistas de crédito.

## As Redes Neurais no Mercado de Títulos

### Prevendo a performance do preço de ações: uma aproximação por Redes Neurais

A previsão da performance de preço de ações envolve a interação de muitas variáveis tornando-a muito difícil e complexa. Geralmente utilizam-se as demonstrações financeiras como base para projeções de futuras tendências de preços de ações, às vezes, informações qualitativas também exercem sua influência sobre o valor de uma ação. Técnicas de análise multivariada que combinam tanto variáveis quantitativas quanto qualitativas têm sido extremamente utilizadas em Finanças.

Entretanto, a performance dessas técnicas por diversas vezes não é satisfatória, pouco conclusiva e com baixa precisão. As Redes Neurais, por sua vez, já demonstraram sua habilidade de enfrentar problemas complexos e gerar resultados acurados. O propósito do estudo é aplicar Redes Neurais a um problema dinâmico e complexo num ambiente de negócios e investigar sua capacidade de prever a performance de preço de ações. Como base de comparação utilizaram-se resultados de uma análise discriminante multivariada.

A Rede Neural foi estruturada em quatro camadas, utilizando um algoritmo de aprendizagem do tipo de *back propagation* e uma função sigmoideal como função de ativação.

A comparação entre os resultados da Rede Neural e da Análise Discriminante mostrou que a utilização de Redes Neurais pode melhorar de forma significativa a previsibilidade da performance de preços de ações.

## Testabilidade da APT através de Redes Neurais

A APT (Arbitrage Pricing Theory) oferece uma alternativa aos métodos tradicionais de precificação de ativos em Finanças. Na maioria dos estudos uma metodologia estatística chamada *factor analysis* é empregada para se testar ou estimar o modelo APT. O maior problema é que este tipo de metodologia não identifica nem o número e nem a definição das variáveis que influenciam os preços dos ativos. Como solução para esse problema este trabalho usa uma simples Rede Neural de *back propagation* para aprender a interação entre os fatores de mercado e o retorno dos títulos.

Assim, através da utilização de Redes Neurais pode-se identificar quantos são os fatores a influenciar o preço dos ativos e quais são esses fatores.

## **Previsões financeiras e a utilização de Redes Neurais**

### **Redes Neurais como alternativa à regressão**

Os modelos estatísticos lineares estão bem difundidos como ferramentas úteis de análise quantitativa. Alguns estudos ainda apontam a análise de regressão como sendo o mais popular dos métodos quantitativos utilizados em negócios e finanças.

As Redes Neurais apresentam uma alternativa viável aos modelos clássicos de regressão. Os principais motivos para se considerar a utilização de Redes Neurais em oposição aos modelos regressivos tradicionais são: a capacidade das primeiras aprenderem com a experiência, poderem generalizar e “enxergar” através de ruídos e distorções nos dados, além de encontrar as transformações certas para as variáveis, identificar relações lineares fracas e administrar outliers. Esse estudo aparece como tentativa de demonstrar essas vantagens de Redes Neurais comparando-a com modelos regressivos que utilizam a mesma base de dados.

O estudo mostrou que em diversas ocasiões as Redes Neurais realmente apresentaram performance superior àquela dos métodos tradicionais, mas em alguns dos casos isso não aconteceu indicando que não é só construir uma Rede Neural e esperar que seus resultados serão sempre os melhores, é necessário testá-la após sua construção, além de se utilizar muito critério na definição de sua arquitetura, escolha de dados de treinamento e teste, isto é, nas etapas de criação da rede.

## **Administrando Estratégias de Previsão de taxas de câmbio com Redes Neurais**

As teorias tradicionais de previsão de taxas de câmbio incluem médias móveis, valor médio e osciladores. Essas técnicas são complementares, enquanto médias móveis, por exemplo, funcionam bem com um mercado que segue uma tendência, técnicas de osciladores funcionam melhor não quando o mercado segue uma tendência, mas quando há oscilações significativas.

Este trabalho mostra uma Rede Neural que utiliza previsões de um portfólio de estratégias, além de informação contextual, para trocar estratégias de negociação. A idéia é prever qual das estratégias é a que trará melhores resultados no contexto atual e, assim, minimizar possíveis perdas.

A Rede Neural apresentada escolhe qual das estratégias deve ser utilizada e até quando deve ser mantida. Os retornos utilizando a regra de decisão da Rede foram superiores quando comparados a utilização de uma única estratégia durante todo o período. Acreditam os autores que os resultados obtidos nesse caso podem ser confirmados em outros mercados de moedas.

## **Conclusão**

Este estudo sem dúvida serve como demonstração do alto potencial de utilização das Redes Neurais no âmbito das Finanças, além da extensiva pesquisa acadêmica realizada sobre o assunto ao redor do mundo.

Apesar disso, foi verificado que o uso comercial e cotidiano desses modelo, mesmo que crescente ainda é reduzido frente seu potencial. Um desconhecimento do assunto pelos potenciais usuários, a dificuldade de se replicar os resultados e a dificuldade na interpretação dos resultados obtidos pela rede parecem explicar essa subutilização da técnica de Redes Neurais nos diversos campos das Finanças.

Assim, esperamos que este seja mais um trabalho a contribuir para a difusão desse tipo de modelagem buscando esclarecer seu funcionamento, sua racionalidade e apontar suas mais diversas utilidades para aqueles envolvidos no ambiente financeiro.

## Revisão Bibliográfica

AHMADI H., "Testability of the Arbitrage Pricing Theory by Neural Network", *Proceedings of the IEEE International Conference on Neural Networks*, San Diego, 1990, IEEE, pgs. I385-I393.

BEALE R. e JACKSON T., *Neural Computing*. Bristol, Inglaterra : Adam Hilger, 1990.

BROWN C. E. e COAKLEY R. R., "Artificial Neural Networks applied to Ratio Analysis in the Analytic Review Process", *Intelligent Systems in Accounting. Finance and Management* 2, 1993, pgs. 19-39.

BUTLER C. e CAUDILL M., *Naturally Intelligent Systems*. Cambridge, Massachussets : MIT Press, 1990.

CARPENTER G. e GROSSBERG S., "A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machine", *Computer Vision, Graphics and Image Processing* 37. 1987, pgs. 54-115.

CAUDILL M., "Embedded Neural Networks", *AI Expert*. Dezembro de 1989, Abril de 1990, Junho de 1990, Julho de 1990, Setembro de 1990, Dezembro de 1990, Abril de 1991.

COATS P. K. e FANT L. F., "Recognizing financial distress patterns using a Neural Network tool", *Financial Management*, Outono de 1993, pgs. 142-155.

DUTTA S. e SHEKKAR S., "Bond Rating: A Nonconservative Application of Neural Networks", *Proceedings of the IEEE International Conference on Neural Networks*, Julho de 1988, IEEE.

JENSEN H. L., "Using Neural networks for Credit Scoring", *Managerial Finance* 18, no.6, 1992, pgs. 116-30.

HILL T., MARQUEZ L., REMUS W. e WORTHLEY R., "Neural Network Models as an Alternative to Regression", *Proceedings of the IEEE 24<sup>th</sup> Annual Hawaii International Conference on Systems Sciences*, vol. IV, 1991, IEEE, pgs. 129-135.

HECHT-NIELSON R., *Neurocomputing*. Reading, Massachussets : Addison Wesley, 1990.

HOPFIELD J., "Neural Networks and Physical Systems with Emergent Collective Computational Abilities", *Proceedings of the National Academy of Science USA* 79. 1985, pgs. 141-52

- KHANNA T., *Foundations os Neural Networks*. Reading, Massachusets : Addison Wesley, 1990.
- KOHONEN T., *Self-Organization and Associative Memory*. Berlim : Springer-Verlag, 1984.
- LIPPMAN R. P., "Review of Neural Networks for Speech Recognition", *Neural Computation* 1, no. 1, 1989, pgs. 1-38.
- MAROSE R. A., "A financial Neural Network Application", *AI Expert*, Maio de 1990, pgs. 50-53.
- PODDIG T., "Bankruptcy Prediction: A Comparison with Discriminant Analysis"
- RAHIMIAN E., SINGH S., THAMMACHOTE T. e VIRMANI R., "Bankruptcy Prediction by Neural Network".
- REFENES A. e ZAIDI A., "Managing Exchange-Rate Prediction Strategies with Neural Networks".
- SINGLETON J. C. e SURKAN A. J., "Bond Rating with Neural Networks".
- SWALES G. e YOON Y., "Predicting Stock Price Performance: A Neural Network Approach", *Proceedings of the IEEE 24<sup>th</sup> Annual Hawaii International Conference of Systems Sciences*, Janeiro de 1991, IEEE, pgs. 156-162.