

Utilização de Redes Neurais Artificiais na Análise de Risco de Crédito a Pessoas Físicas

Elson Felix Mendes Filho †, André Carlos Ponce de Leon Ferreira de Carvalho†,
Alberto Borges Matias ‡

† Laboratório de Inteligência Computacional / SCE / ICMSC, USP
São Carlos, SP - Brasil.
e-mail: {prico, andre}@icmsc.sc.usp.br

‡ Centro de Pesquisas em Crédito e Banking / FEA - RP, USP
Ribeirão Preto, SP - Brasil.
e-mail: matias@.usp.br

Abstract - The growing automation of financial activities requires the use of sophisticated technologies to satisfy exigent users. As a result, the finance market is looking for new computational techniques to satisfy its needs. These techniques include Artificial Neural Networks, ANN. ANN are being used in a large number of financial tasks. This work presents a performance analysis of the Multi Layer Perceptron ANN, trained with the Backpropagation algorithm, to evaluate risks in credit applications.

Resumo - A crescente automação de atividades comerciais e bancárias requer a utilização de tecnologias cada vez mais sofisticadas para satisfazer usuários cada vez mais exigentes. Como consequência, o mercado financeiro está sempre buscando novas gerações de técnicas computacionais que satisfaçam suas necessidades mais refinadas. Entre estas técnicas estão as Redes Neurais Artificiais (RNA). Este trabalho apresenta uma análise do desempenho obtido por RNA *Multi Layer Perceptron*, treinadas com o algoritmo Backpropagation, em uma aplicação de avaliação de risco de inadimplência no crédito financeiro.

1 Introdução

O crédito a pessoas físicas, nas diversas modalidades financeiras de cartão de crédito, crédito direto ao consumidor e cheque especial, tem sido tratado empiricamente ou por sistemas de *credit score* baseados em análise discriminante ou de regressão logística. No entanto, nos últimos anos, em razão do crescimento do mercado de crédito ao varejo no Brasil, o assunto passou a merecer maior atenção e preocupação, notadamente em razão da forte elevação das taxas de inadimplência.

Este tipo de aplicação caracteriza-se por estar fundamentada em enorme quantidade de dados sobre a clientela e por mudanças no perfil de comportamento dos tomadores de crédito, decorrente de mudanças nas variáveis econômicas: quem não seria inadimplente sob condições normais, poderá vir a sê-lo sob redução da liquidez da economia. Os prejuízos causados aos doadores de recursos são enormes, e qualquer redução do risco poderá implicar em grandes benefícios.

Na maioria dos ambientes de avaliação de crédito, os gerentes trabalham com uma enorme variedade de informações vindas das mais diversas fontes. Muitas destas informações podem ser incompletas, ambíguas, parcialmente incorretas ou de relevância dúbia. Os gerentes analisam estas informações de maneira muito subjetiva e muitas vezes não conseguem explicar os processos de tomada de decisões,

embora consigam apontar os fatores que influenciam as decisões. Além disso, estes ambientes são dinâmicos, com constantes alterações, onde as decisões devem ser tomadas rapidamente.

Redes Neurais Artificiais (RNA) oferecem uma eficiente alternativa para o tratamento de informações dessa natureza, uma vez que podem ser modificados mais facilmente que sistemas convencionais, são de utilização rápida, e são mais simples que os métodos convencionais na modelagem não linear, o que lhes dá uma grande vantagem sobre vários métodos estatísticos utilizados em economia e finanças, que são lineares[11].

A área financeira sempre teve grande interesse em aplicações da Inteligência Computacional para o tratamento destes problemas [2]. Vários projetos de sistemas inteligentes para aplicações de cartão de crédito vêm sendo implementados [3]. Um sistema inteligente para tomada de decisão sobre autorização de compra com cartão de crédito utilizado pela *American Express* resultou em uma economia de 20% no tempo médio gasto em cada transação e a qualidade das decisões tomadas por este sistema foram em média 50% melhores que decisões tomadas pelo pessoal de autorização de crédito [10].

Mastercard e *Visa* estão investindo em projetos para construção de sistemas semelhantes, utilizando RNA, para avaliação de propostas de novos clientes, detecção de fraudes, e avaliação para autorização de compra (“*Visa using neural networks to identify cardholder fraud*”, Card News, March 20, 1995 v10 n5 p3 (1)).

As seções seguintes apresentam características das RNA que justificam sua adequação para a solução de problemas de avaliação de crédito; análise dos principais aspectos relacionados ao problema de avaliação de crédito; a metodologia utilizada para a aplicação de uma RNA na solução de um problema real de avaliação de crédito; e análise dos resultados obtidos.

2 Redes Neurais Artificiais

Redes Neurais Artificiais (RNA) são modelos de processamento de informação inspirados em uma estrutura natural: o cérebro humano. Estes modelos não pretendem replicar a operação do cérebro, apenas utilizam como inspiração fatores conhecidos sobre o seu funcionamento, visando obter melhores desempenhos na resolução de problemas para os quais métodos tradicionais de computação têm se mostrado inadequados.

As RNA são compostas por unidades de processamento simples (“neurônios”) que computam certas funções matemáticas; estas unidades são interligadas por um grande número de conexões (“sinapses”) associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada unidade da rede. Estas unidades podem estar dispostas em camadas como ilustrado na Figura 1. O conhecimento é adquirido por meio de um processo de treinamento onde as conexões entre as unidades são ajustadas através de mudanças dos valores de seus pesos.




Figura 1 - Rede neural.

O modelo de RNA utilizado neste projeto, o *Multi Layer Perceptron*, é muito apropriado aos problemas de avaliação e o seu treinamento pode ser feito com o algoritmo *backpropagation* [9]. Este é um dos algoritmos mais utilizados para o treinamento de redes com mais de uma camada. Este algoritmo ajusta pesos da rede utilizando um método de gradiente descendente. Este modelo foi escolhido por ser um modelo neural amplamente aceito e pelos excelentes resultados que tem produzido nas áreas de classificação, reconhecimento de padrões, e previsão.

3 Avaliação de Risco de Crédito

O problema de avaliação de risco de crédito pode ocorrer na forma de solicitação de cartão de crédito, crediário, autorização de compra, empréstimos bancários ou cheque especial. Nestes casos, os dados do cliente são analisados por gerentes que decidem quanto à aceitação ou rejeição da aplicação, baseados em informações sobre o cliente, em sua experiência gerencial e em relatórios de departamentos administrativos ou agências de crédito. Esta é uma tarefa muito trabalhosa, demorada e que tem um impacto significativo nos lucros das empresas. As decisões devem ser muito criteriosas, pois decisões erradas podem provocar não apenas prejuízos financeiros à instituição de crédito, mas também prejuízos financeiros e morais aos seus clientes.

Este método de avaliação apresenta os seguintes problemas:

- **Baixa Eficiência.** Consomem muito tempo e necessitam de pessoal especializado.
- **Baixa Performance.** A experiência de grande parte dos gerentes não é suficientemente abrangente para produzir avaliações meticulosas.
- **Pouca Flexibilidade.** Uma grande experiência é necessária antes que os gerentes possam realizar esta tarefa. Este método reage muito vagorosamente a mudanças.
- **Inconsistência.** Diferentes gerentes utilizam critérios distintos de avaliação.

Com níveis de inadimplência elevado nas aplicações de crédito ao varejo, as instituições financeiras foram em busca de sistemas mais apurados para a gerência de risco. Inicialmente, técnicas estatísticas, como análise discriminante e regressão logística, foram utilizadas em sistemas automatizados para auxílio nas avaliações, mas alguns aspectos destas técnicas não são muito apropriados para estes problemas [3]. Em razão disto, novas abordagens ao problema tornaram-se necessárias. Entre as mais proeminentes estão os sistemas especialistas tradicionais e os sistemas neurais.

A primeira, utiliza sistemas baseados em regras, onde o conhecimento de especialistas na área é adquirido através de entrevistas e outros métodos que levem à definição de um conjunto de regras. Esta abordagem modela o processo de avaliação, através de regras obtidas dos especialistas e não através de registros anteriores das aplicações. Além disso, a extração de regras não é um processo simples. Embora esta abordagem evite os problemas de consistência e eficiência, ela não evita os problemas de performance e flexibilidade.

Os sistemas neurais oferecem uma abordagem mais adequada para o tratamento de aplicações desta natureza. Uma RNA pode ser treinada utilizando grandes quantidades de exemplos significativos, o que contribui para obtenção de performance elevada. Ou seja, a avaliação é modelada através de exemplos de aplicações bem ou mal sucedidas, encontrados nos históricos dos clientes. Desta forma, a rede é capaz de encontrar relações entre as informações e incorporar aspectos subjetivos do processo de avaliação da empresa.

Estes sistemas são mais flexíveis, pois quando mudanças são necessárias devido a aspectos políticos, econômicos ou regionais, pode-se alterar apenas o conjunto de exemplos de treinamento e alguns parâmetros da rede, o que não requer mudanças estruturais no sistema. Estes sistemas podem, até mesmo, detectar esta necessidade e realizar um novo treinamento automaticamente. Também são considerados consistentes e eficientes, pois um mesmo sistema pode ser utilizado nos diferentes postos de atendimento, ser operado por pessoal sem experiência gerencial e realizar avaliações mais rapidamente. Permitindo às empresas explorarem seu ambiente de maneira privilegiada e assegurarem sua perenidade, transformando dados em informações úteis à tomada de decisão, aumentando o valor agregado dos seus produtos e serviços [1].

4 Projeto de Redes Neurais para Avaliação de Crédito

Neste trabalho é tratado o problema de avaliação de risco de inadimplência do banco *Banestado*. Este projeto está sendo desenvolvido por membros do Laboratório de Inteligência Computacional e do Centro de Pesquisas em Crédito e Banking. Os dados utilizados fazem parte de uma base de transações de crédito do banco.

Durante o desenvolvimento deste projeto foi criado um protótipo do sistema de avaliação de risco [6] utilizando a linguagem *Delphi* em um *PC Pentium 100 Mhz* e todo o desenvolvimento e treinamento das redes foi feito em uma estação *SUN Ultra 1 Model 140* de *143 MHZ* com *64 Mbytes* de memória e sistema operacional *Solaris 2.5*.

Para auxiliar o desenvolvimento das redes para a solução do problema proposto foi utilizado o simulador *SNNS - Stuttgart Neural Network Simulator* [12,4] que oferece um ambiente eficiente e flexível para pesquisa e aplicação de redes neurais. O componente *XGUI - Graphical User Interface*, deste simulador, foi utilizado para a criação das redes e avaliação preliminar das arquiteturas geradas, e o componente *BATCHMAN- Batch Simulator*, que fornece um interpretador com uma sintaxe muito adequada à simulação de RNA, foi utilizado através de programas que permitiram a construção de esquemas de treinamento mais elaborados e a análise mais aprofundada dos desempenhos obtidos pelas redes.

O protótipo do sistema de aplicação criado consiste de um módulo gerenciador de banco de dados, um módulo para a criação de conjuntos de dados, pré-processamento dos dados e conversão de tipos para o formato do simulador e um módulo que utiliza a rede para a avaliação.

A seguir serão apresentadas a metodologia de desenvolvimento utilizada e a análise dos resultados obtidos.

4.1 Metodologia

A metodologia utilizada nas diferentes fases deste projeto incluiu várias estratégias para tratamento das informações das bases de dados, seleção, treinamento e testes das redes, como serão discutidas nas próximas sub-seções.

4.1.1 Coleta de Dados

Nesta primeira fase foram reunidos todos os dados pertinentes e potencialmente úteis à tarefa. Estes estavam contidos nas bases de dados fornecidas pelo banco *Banestado*, no formato *dbase (.dbf)*, o que facilitou o processo de coleta e criação do módulo gerenciador destas bases de dados do sistema de aplicação. Os dados coletados incluíam informações pessoais dos clientes; informações sobre a aplicação de crédito solicitada e um histórico sobre a adimplência destes clientes, o que permitiu a classificação destes clientes em duas classes: adimplentes e inadimplentes.

A Figura 2 apresenta uma tela do gerenciador contendo as informações reunidas de uma transação de crédito.

The screenshot shows a window titled "Operações Sobre a Base" with a toolbar at the top. The form contains the following data:

- Nome: Luiz Carlos Alvares de Araujo
- Sexo: Masculino, Feminino
- Estado Civil: Solteiro, Casado, Separado Judic., Viúvo, Divorciado
- Data de Nascimento: 06 04 1947
- Tempo de Residência: 30
- Salário Atual: 200000
- Honorários: 0
- Pró-Labore: 0
- Outros Rendimentos: 0
- Número do Cartão: 2018861
- Data da Aprovação: 06 05 1995
- Data da Capitalização: 06 05 1995
- Valor do Patrimônio: 100000
- Atividade Principal: 303
- Profissional Liberal:
- Adimplente:
- Tipo de Residência: Própria, Alugada, Com Parentes, Funcional

Figura 2 - Informações sobre uma transação de crédito.

4.1.2 Pré-processamento dos Dados

Dados simbólicos como Sexo, Estado Civil, Tipo de Residência, entre outros, foram transformados em classes numéricas, mais adequadas para utilização neste tipo de rede. Dados numéricos como Salário Atual, Valor do Patrimônio, entre outros, foram normalizados para o intervalo [0, 1].

Todos os dados de uma transação são pré-processados, agrupados em vetores numéricos e arranjados de forma aleatória em arquivos do formato padrão do simulador. Estas operações foram feitas através do módulo de pré-processamento do protótipo criado.

A Figura 3 mostra o padrão resultante das informações da transação ilustrada na Figura 2.

```
# Input pattern 1:
0 0.00150 0.05000 0.02000 0.73034 0.06032 0.40952 1 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0.10127 1
0 0 0 0.03748 0 0 0.00007

# Output pattern 1:
1 0
```

Figura 3 - Exemplo de um padrão resultante do pré-processamento.

4.1.3 Separação dos Conjuntos de Dados

Os dados coletados, 5635 registros, estavam divididos em duas classes: Adimplentes, 5414 registros (96.07%) e Inadimplentes, 221 registros (03.93%). Eles foram separados em conjuntos de treinamento, validação e teste, para serem utilizados em cada uma das fases do desenvolvimento da rede. Estes conjuntos foram cuidadosamente escolhidos para cobrir extensivamente o domínio do problema, seguindo uma metodologia semelhante à proposta em [11], como mostra a tabela da Figura 4.

O conjunto de validação foi composto por uma porcentagem, neste caso 10%, dos registros originais, escolhidos aleatoriamente e mantendo a mesma proporção de classes presentes nos dados originais.

O conjunto utilizado no treinamento foi composto pelos registros da classe com o menor número de registros (Inadimplentes) que não entraram no conjunto de validação e teste e o mesmo número de registros da outra classe, escolhidos aleatoriamente.

Alguns conjuntos de teste também foram criados; maiores detalhes sobre estes conjuntos serão vistos em uma secção posterior.

Classe	Dados Originais	Conj. de Treinamento	Conj. de Validação.
Adimplentes	5338	194	533
Inadimplentes	215	194	21
Total:	5635	388	554

Figura 4 - Separação dos dados em conjuntos.

4.1.4 Seleção da Arquitetura

A escolha da configuração adequada da rede teve impacto substancial no desempenho do modelo. Esta tarefa foi feita de forma empírica: foram analisadas preliminarmente várias arquiteturas e parâmetros diferentes utilizando a *XGUI* do simulador; foram dadas pontuações às redes analisadas, de acordo com suas características de aprendizado e capacidade de generalização.

As três arquiteturas escolhidas: 38-5-2, 38-20-8-2 e 38-20-10-2 foram as que apresentaram aprendizado mais estável e maior capacidade de generalização.

A Figura 5 mostra alguns resultados preliminares, obtidos durante 300 ciclos de treinamento, onde pode-se perceber os efeitos do parâmetro de aprendizado η , termo *momentum* μ e arquiteturas.

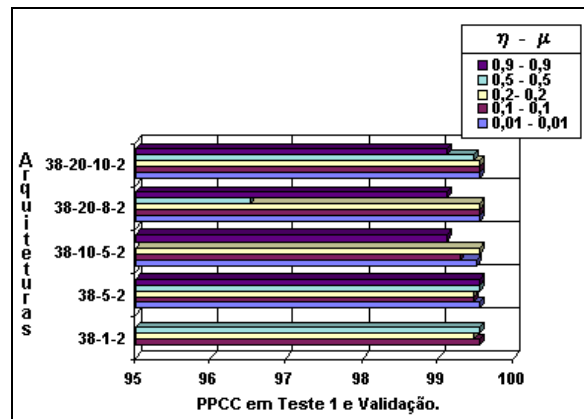


Figura 5 - Efeito dos parâmetros e da arquitetura.

4.1.5 Treinamento das Redes

O treinamento foi realizado utilizando o algoritmo *backpropagation* com termo *momentum* durante 1000 ciclos e o estado das redes foram gravados em arquivos nos ciclos em que eram apresentadas as menores taxas de erro no conjunto de validação.

Foi utilizada uma estação SUN Ultra 1 Model 140 e o tempo médio de treinamento foi 23 minutos, sendo que o tempo médio de propagação de um ciclo foi de 0,107 s. e de propagação seguida de retropropagação de um ciclo foi de 0,294 s.

O gráfico de erros quadráticos médios nos conjuntos de treinamento e validação durante os 1000 ciclos de treinamento da rede 38-20-8-2, com η : 0,025 e μ : 0,025, é apresentado na Figura 6.

O ponto grifado foi o ciclo 127 de melhor validação neste treinamento.

(EQM Validação: 0,0088 - EQM Treinamento: 0,0689).




Figura 6 - Gráfico de erro (EQM) de treinamento e validação.

4.1.6 Teste das Redes

Foram realizados dois testes para analisar o desempenho das arquiteturas neurais escolhidas, utilizando diferentes amostras. Uma amostra contendo 10% dos padrões originais escolhidos aleatoriamente, mantendo a mesma proporção de classes da base (Teste1). E uma amostra com todos os padrões da base (Teste2). Foram calculados os erros quadráticos médios (EQM) e as porcentagens de padrões corretamente classificados (PPCC).

Os resultados apresentados na figura 7 mostram os desempenhos das redes escolhidas.

Arquiteturas	Teste1		Teste2	
	EQM	PPCC	EQM	PPCC
38-5-2	0,0115	99,47 %	0,02169	99,69 %
38-20-8-2	0,0104	99,47 %	0,02363	99,71%
38-20-10-2	0,0091	99,47 %	0,02214	99,69%

Figura 7 - Desempenho das redes nos testes.

4.2 Resultados

A arquitetura que apresentou melhores resultados foi: 38-20-8-2, a rede foi inicializada com pesos aleatórios no intervalo $[-0.5, 0.5]$, com taxa de aprendizado η : 0.025 e termo momentum μ : 0.025, o treinamento foi realizado durante 1000 ciclos e utilizou o algoritmo de aprendizado *backpropagation* com *termo momentum*.

Os erros quadráticos médios (EQM), o número de padrões classificados erradamente (NPCE), o número de padrões classificados corretamente (NPCC) e a porcentagem de padrões classificados corretamente (PPCC) para todos os padrões contidos na base divididos por classes são mostrados na Figura 8.

	EQM	NPEC	NPCC	PPCC
Adimplentes	0.01923	1	5413	99.98 %
Inadimplentes.	0.13151	15	206	93.21 %

Figura 8 - Resultados nos conjuntos de dados.

Foi notado que alguns padrões da classe inadimplente dificilmente são classificados corretamente pelas redes, um estudo preliminar revelou que estes padrões eram considerados exeções, realmente difíceis de serem avaliadas e que estas poderiam não estar bem representadas no conjunto de treinamento.

Foi utilizada uma matriz de custos para classificar o desempenho da rede na solução do problema. Esta matriz, apresentada na Figura 9 indica que é pior classificar um cliente como adimplente quando ele é inadimplente (3), do que classificar como inadimplente quando ele é adimplente (1).

	p. Adim.	p. Inad.
Adim.	0	1
Inad.	3	0

Figura 9 - Matriz de custos de padrões classificados erradamente.

Os padrões erradamente classificados são multiplicados pelos pesos dados nesta matriz e são somados. A rede escolhida 38-20-8-2 foi a que apresentou a menor taxa de custo: 46.

5 Conclusões e Trabalhos Futuros

De modo a avaliar o modelo proposto, foi utilizado um conjunto de dados reais de aplicações de crédito ao varejo, os resultados obtidos confirmaram a eficiência do modelo e da metodologia utilizada para a solução deste tipo de problema. Outros resultados anteriores apresentados em [6] também confirmavam a eficiência do modelo para avaliação de crédito, no qual foram utilizados outros conjuntos de dados, sobre aplicações reais de cartões de crédito, para *benchmark* [7].

A rede selecionada foi inserida no módulo de avaliação do sistema, para então ser utilizada para previsão do risco de inadimplência de outros clientes. O protótipo construído revelou-se uma ferramenta muito útil para auxílio à gestão de crédito financeiro massificado.

Os dados utilizados apresentavam históricos com poucos exemplos de clientes inadimplentes, o que dificultou o processo de treinamento. Este pequeno número de exemplos se deve ao fato de ser utilizada pelo banco, uma avaliação preliminar de novos clientes, *pré-screening*, a cargo de seus gerentes e analistas. Assim a rede gerada neste projeto será eficiente para análise de casos que passem por esta primeira avaliação.

Pode ser adicionado, futuramente, um estudo da rentabilidade do banco em cada transação, e formar assim um maior número de classes de clientes. Uma rede treinada utilizando estas várias classes poderia ser uma boa alternativa para a determinação de *behavioral score*, pontuação relativa ao comportamento dos clientes [8]. Seria interessante coletar também os dados das propostas rejeitadas no *pré-screening*. Redes treinadas com todas estas informações poderiam ser utilizadas como uma ferramenta completa e mais apurada para todas as transações que envolvessem avaliação de risco de crédito.

Está sendo desenvolvido um módulo de processo evolutivo para seleção de parâmetros de aprendizado e de arquitetura das redes, semelhante ao proposto em [5]. Toda a metodologia e estratégias empregadas aqui foram desenvolvidas levando este fato em consideração, o que facilitará a construção deste módulo. Futuramente, através deste módulo serão escolhidas as arquiteturas mais adequadas à aplicação de maneira automática e utilizando uma estratégia de busca mais atraente.

6 Agradecimentos

Os autores agradem ao *CNPq* e *Fapesp* pelo suporte financeiro, aos colegas do LABIC pelo grande incentivo, à Rodrigo J. Amendola e à Fernando C. de Almeida, pelo auxílio neste trabalho.

7 Referências

- [1] F. Almeida, P. Dumontier, “O uso de redes neurais em avaliação de riscos de inadimplência”, *Revista de Administração*, vol. 31, pp. 52-63, Março 1996.
- [2] C. Apté, J. Kastner, editors, “Financial Applications. Special Issue”, *IEEE Expert*, vol. 2, n. 3, 1987.
- [3] C. Carter, J. Catlett, “Assessing Credit Card Applications Using Machine Learning”, *IEEE Expert*, vol. 2, n. 3, 1987.
- [4] H. Diniz, E.F. Mendes F., A.C.P.L.F. Carvalho, “SNNS - Manual de Referência Básica”, *Relatórios Técnicos do ICMSC*, Universidade de São Paulo - Brazil, 1996.
- [5] M. Mandisher, “Representation and Evolution of Neural Networks”, *Technical Report*, Universität Dortmund - Germany, 1993.
- [6] E.F. Mendes F., A.C.P.L.F. Carvalho, “NeurAval - Sistema Neural para Avaliação de Crédito”, aceito para publicação no *XXIX Congresso Nacional de Informática e Telecomunicações -SUCESU'96*, Natal - RN, 04-09 Novembro 1996.
- [7] L. Prechelt, “Proben 1: A set of Neural Network Benchmark Problems and Benchmarking Rules”, *Technical Report: 21/94*, Universität Karlsruhe - Germany, 1994.
- [8] R.D. Ribeiro, “Ir mais além da modelagem: ser capaz de tirar as melhores vantagens de seus modelos de scoring por meio da automação”, *Proc. of the Conference Credit Scoring & Behavioural Scoring*, São Paulo-SP, 8-9 Julho 1996.
- [9] D.E. Rumelhart, G.E. Hinton, R.J. Williams, “Learning internal representation by error propagation”, in *Parallel Distributed Processing*, pp. 318-362, MIT Press, 1986.
- [10] P. Treleaven, S. Gonnatilake, “Intelligent Financial Technologies”, *Proc. of the Workshop on Parallel Problem Solving From Nature: Applications in Statistics and Economics*, 1992.
- [11] R. Trippi, E. Turban, editors, *Neural Networks in Finance and Investing*. Chicago: Probus Publishing Company, 1993.
- [12] A. Zell, *et al.*, “SNNS Stuttgart Neural Network Simulator - User Manual, Version 4.1”, *Technical Report: 6/95*, I.P.V.R., Universität Stuttgart - Germany, 1995.