

4

Técnicas de Inteligência Computacional na Avaliação do Problema de Cargas Concentradas

4.1

Introdução

Os resultados apresentados no capítulo 3 demonstraram que as redes neurais possuem uma grande capacidade de previsão da carga última e boa generalização para novos dados. Porém, deve-se ressaltar que a matemática intrínseca das redes neurais não é visível (modelo tipo caixa preta) e a técnica é extremamente dependente dos resultados experimentais disponíveis.

Para uma melhor compreensão do problema, seria preciso conhecer os critérios usados pela rede neural, isto é, que regras a rede formula matematicamente para representar os diferentes fenômenos. Porém, as características das redes neurais e a complexidade da arquitetura empregada tornam isso inviável.

Este capítulo apresenta o desenvolvimento de um sistema de classificação do fenômeno físico baseado em um modelo neuro-fuzzy hierárquico para classificar o fenômeno físico quanto aos diferentes comportamentos estruturais de forma mais gradual, uma vez que não é possível definir limites exatos para este problema.

Neste trabalho, também foi aventada a possibilidade da utilização de algoritmos genéticos para a criação de uma nova fórmula de projeto e um estudo sobre a utilização de uma única rede neural de previsão de carga parametrizada pela carga de plastificação. Estes modelos e os resultados encontrados pelo sistema de classificação são apresentados a seguir.

4.2

Geração de uma Nova Fórmula por Algoritmos Genéticos

A geração de uma nova fórmula para a carga de ruína de vigas de aço submetidas a cargas concentradas caracteriza um problema complexo, pois

envolve a interação de diversos parâmetros e a influência concomitante de diferentes comportamentos estruturais na mesma viga. Uma das técnicas da programação genética é a regressão simbólica (Koza, 1994), desenvolvida para encontrar uma expressão matemática que se ajuste melhor a um conjunto de dados, a partir da informação das variáveis relevantes.

Apesar da regressão simbólica por programação genética ser a técnica mais indicada para gerar uma nova fórmula empírica para o problema de cargas concentradas, não existem softwares desta técnica que permitam a utilização de tantas variáveis e seria necessário desenvolver uma ferramenta para este estudo, o que não fazia parte do escopo desta tese. Desta forma, a primeira abordagem nesta área (Fonseca et al., 2000) utilizou apenas algoritmos genéticos com o objetivo de otimizar coeficientes e potências de fórmulas existentes (Bergfelt, 1979), (Roberts & Newark, 1997).

Uma das primeiras equações para o problema, proposta por Lyse & Godfrey (1935), ainda está em uso. Esta fórmula (2.1) avalia a resistência da alma da viga sem considerar problemas de instabilidade. Desta forma, a fórmula tem sido aplicada em diversas normas internacionais, para casos onde a alma é mais compacta, tendo sido desenvolvida para vigas com esbeltez de alma (h/t_w) em torno de 52. Dentre as fórmulas desenvolvidas por outros pesquisadores, bons resultados foram obtidos pelas fórmulas de Bergfelt (1979) e Roberts & Newark (1997).

A fórmula de Bergfelt (2.7) foi desenvolvida com o objetivo de considerar a influência de diversos parâmetros, no entanto os resultados não foram muito superiores aos trabalhos anteriores. Os melhores resultados foram encontrados pela fórmula de Roberts & Newark (2.12).

Os critérios para utilização de cada uma das fórmulas variam de norma para norma, estando no entanto relacionados com a esbeltez da alma e seguindo os métodos tradicionais. Ou seja, limites rígidos são estabelecidos para a utilização de cada fórmula, prejudicando assim os casos intermediários entre a instabilidade e a plasticidade. Uma fórmula mais eficaz deve fazer uma combinação entre estes dois estados limites últimos. A obtenção dos coeficientes e potências desta nova fórmula pode ser realizada utilizando uma otimização por algoritmos genéticos.

A partir da fórmula de Robert & Newark (2.12) e dos parâmetros mais significativos da fórmula de Bergfelt avaliados em uma análise paramétrica (Fonseca, 1999) foi construída uma estrutura de fórmula com coeficientes e potências K_i a serem calibrados. Esta estrutura é apresentada na equação 4.1. O “cromossomo”, definido como uma possível solução para o problema, corresponde aos valores K_i da equação. Foi utilizado o software Evolver (Winston & Albright, 1999), ligado ao Microsoft Excel, para a evolução. Após vários ajustes foram definidos:

- População: 3000
- Probabilidade de mutação: 0,15
- Probabilidade de cruzamento: 0,80

A otimização consistiu em minimizar a função de avaliação definida como o erro percentual máximo de todos os 161 dados experimentais (Fonseca et al., 1999) apresentados no Anexo A, sendo este erro a diferença entre os resultados experimentais e os resultados calculados pela fórmula, a cada geração.

$$P_f = \left(\frac{t_w}{h}\right)^{K1} \left[t_w^{K2} (E\sigma_y^w)^{K3} \left(\frac{t_f}{t_w}\right)^{K4} (K5 + K6c_e^{K7} t_w^{K8} t_f^{K9} h^{K10} b_w^{K11}) \right] + \quad (4.1)$$

$$+ K12 \left(\frac{t_w}{h}\right)^{K13} t_w \sigma_y^w (c + K14 t_f)$$

Nesta equação a primeira parcela da soma é referente à instabilidade e a segunda referente à plastificação da alma. Estas parcelas são mais usadas ou menos usadas de acordo com a esbeltez da alma (h/t_w), estabelecendo limites mais graduais na própria fórmula, inspirados na técnica de lógica nebulosa. Depois da evolução dos coeficientes e potências K_i , foi obtida a fórmula apresentada abaixo, que forneceu resultados satisfatórios para todos os dados experimentais avaliados que englobam diferentes problemas de comportamento estrutural (Tabela 4.1).

$$P_f = \left(\frac{t_w}{h}\right)^{0.001} \left[t_w^2 (E\sigma_y^w)^{0.5} \left(\frac{t_f}{t_w}\right)^{0.4} (0.8 + 0.12c_e^{3.3} t_w^{-0.25} t_f^{-0.75} h^{0.95} b_w^{-3.25}) \right] + \quad (4.2)$$

$$+ 0.2 \left(\frac{t_w}{h}\right)^{0.06} t_w \sigma_y^w (c + 1.75 t_f)$$

Tabela 4.1 – Comparação entre resultados das fórmulas

	Fórmula GA	Roberts & Newark (2.12)	Bergfelt (2.7)	Lyse&Godfrey (2.1)
Erro máximo %	30,45	85,19	567,02	117,01
Erro médio %	13,11	12,82	35,66	43,22

Apesar do método ter reduzido o erro percentual da fórmula, foi aventada uma outra abordagem, utilizando apenas os dados referentes a vigas mais esbeltas para a otimização da fórmula. Foram utilizados os 127 dados das vigas de faixas 1 e 2 apresentadas na dissertação de mestrado (Fonseca, 1999), isto é, os dados de carga última até 250 kN apresentados no Anexo A. Os resultados tiveram uma melhora pouco significativa, como pode ser visto a seguir:

Tabela 4.2 - Comparação entre resultados das fórmulas

	Fórmula GA	Roberts & Newark (2.12)	Bergfelt (2.7)	Lyse&Godfrey (2.1)
Erro máximo	28,49	36,92	125,04	117,01
Erro médio	11,43	12,10	23,86	44,05

A fórmula encontrada é apresentada abaixo, e seus resultados mostram que é possível a geração de uma fórmula de projeto mais precisa a partir de um maior conhecimento do problema.

$$P_f = \left(\frac{t_w}{h}\right)^{-0.015} \left[t_w^2 (E \sigma_y^w)^{0.5} \left(\frac{t_f}{t_w}\right)^{0.39} (0.78 + 0.57 c_e^{4.62} t_w^{-2.21} t_f^{2.20} h^{1.19} b_w^{-5.8}) \right] + 1.72 \left(\frac{t_w}{h}\right)^{0.56} t_w \sigma_y^w (c + 3.05 t_f) \quad (4.3)$$

Apesar das restrições de forma impostas, a fórmula empírica obtida com os algoritmos genéticos atingiu resultados satisfatórios para confirmar as vantagens da utilização de uma única fórmula. Apesar dos erros encontrados serem superiores aos fornecidos pelas redes neurais, eles foram inferiores aos fornecidos pelas fórmulas tradicionais de dimensionamento, mesmo quando uma única fórmula para todos os tipos de viga foi adotada. O erro máximo foi inferior a todas

as outras fórmulas, possibilitando a redução dos fatores de segurança necessários a engenharia estrutural.

Deve-se ressaltar que este estudo apenas avalia o desempenho dos algoritmos genéticos e a possibilidade de utilização de uma única fórmula de projeto. Este trabalho poderá prosseguir com a utilização de um programa de regressão simbólica por programação genética que tende a melhorar ainda mais este resultado, garantindo maior liberdade na geração de uma nova fórmula. Deve-se considerar também a possibilidade da utilização dos valores de carga fornecidos pelas redes neurais para a evolução de fórmulas por algoritmos genéticos.

4.3 Rede Neural unificada de previsão da carga crítica

Uma nova abordagem do problema foi a utilização de uma única rede neural de previsão, através da normalização da carga última a partir da divisão por uma fórmula de plastificação da alma (equação 4.4), baseada na equação 2.1 de Lyse & Godfrey.

$$\frac{P_{ex}}{P_n}; \quad \text{onde: } P_n = \sigma_w t_w (c + kt_f) \quad (4.4)$$

O valor adotado para a variável k foi estabelecido através de uma comparação das redes neurais que atingiram uma melhor performance. Alguns dos resultados das redes com k variando de 14 a 17 são apresentados na Figura 4.1. Os melhores resultados foram para um valor de k igual a 17. É importante observar que este valor não tem um significado físico, servindo apenas como parte de um parâmetro de normalização.

Várias arquiteturas de redes neurais foram treinadas e comparadas, variando o número de processadores na camada escondida. Os melhores resultados foram obtidos com 15 processadores, como pode ser observado na Figura 4.2. A Tabela 4.3 apresenta um resumo do desempenho das melhores redes neurais de previsão de carga.

Uma comparação dos erros percentuais da rede selecionada com algumas fórmulas de previsão (2.7, 2.12 e 2.17) é apresentada na Figura 4.3. Verifica-se

que o desempenho da rede unificada de previsão foi tão bom quanto o apresentado no capítulo 3 pelas três redes divididas por faixas de carga e que elas apresentam resultados superiores aos apresentados pelas fórmulas. Estes resultados mostram que uma única rede neural é capaz de prever os resultados de diferentes fenômenos físicos.

Tabela 4.3 – Resultados da rede neural de previsão da carga crítica.

	Treinamento e validação	Testes
Desvio Padrão	7,31	
Erro Percentual médio absoluto	6,71	11,32
Dados com erro inferior a 5%	52,17%	17,65%
Dados com erro entre 5% e 10%	21,01%	29,41%
Dados com erro entre 10% e 15%	16,67%	17,65%
Dados com erro entre 15% e 20%	7,25%	23,53%
Dados com erro entre 20% e 25%	2,17%	11,76%
Dados com erro superior a 25%	0,72%	0%
Percentual de Treinamento-validação-testes	70/20	10

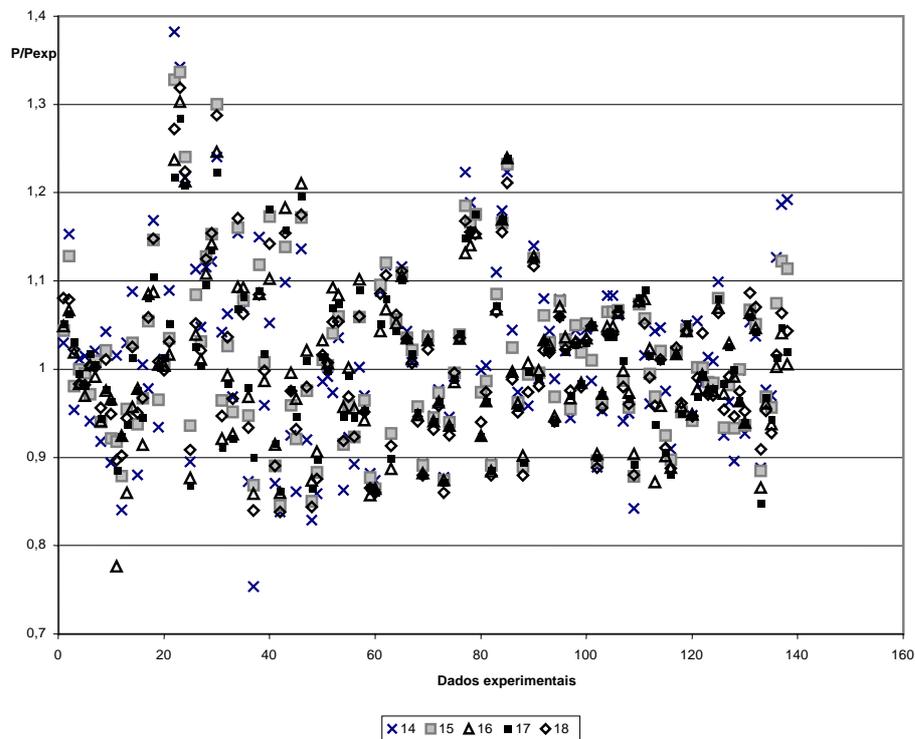


Figura 4.1 – Avaliação do parâmetro de normalização k.

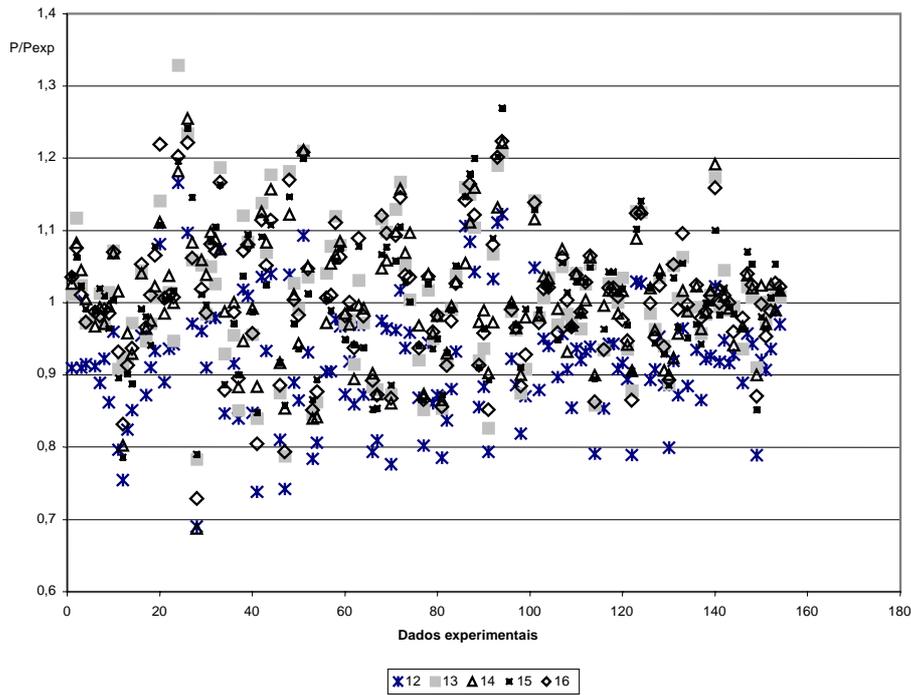


Figura 4.2 – Avaliação do número de processadores na camada escondida.

PUC-Rio - Certificação Digital Nº null

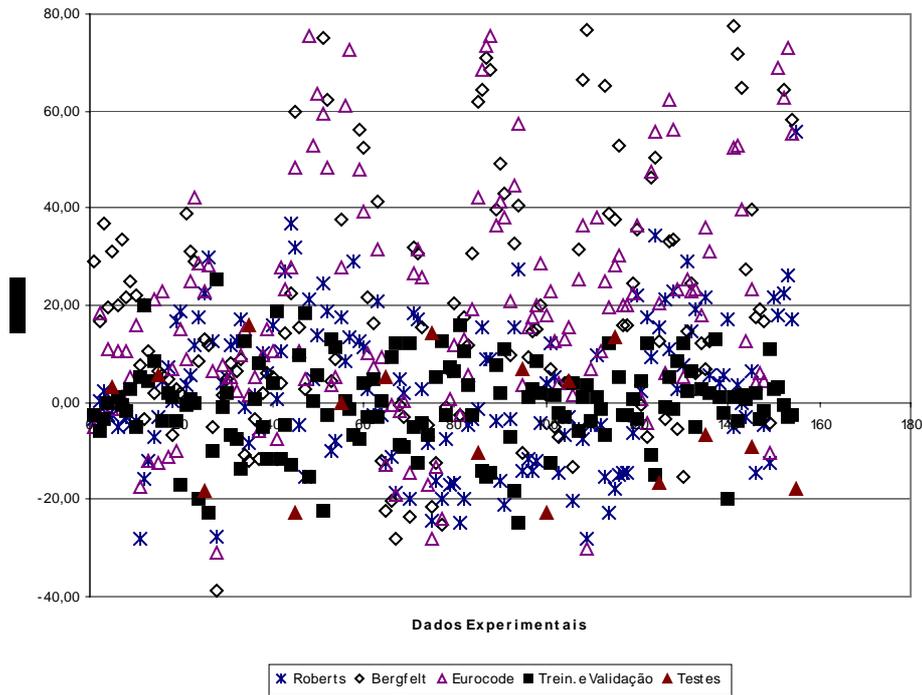


Figura 4.3 – Comparação dos resultados com fórmulas de previsão da carga.

4.4 O Sistema de Classificação do Fenômeno Físico Proposto

O estudo consiste no desenvolvimento de um sistema baseado em um modelo neuro-fuzzy para classificar os dados de acordo com o grau de ativação aos diferentes fenômenos físicos (flambagem, enrugamento e plastificação) e para a obtenção de um conjunto de regras que poderão servir para uma futura análise paramétrica e, conseqüentemente, prever a resistência última de vigas de aço sujeitas a cargas concentradas. Em (Fonseca, 1999), a divisão das classes foi feita pela magnitude da carga e não de acordo com o fenômeno físico associado. Isto tende a provocar distorções na avaliação da carga última, pois vigas com um mesmo valor de carga última podem representar fenômenos físicos diferentes.

Desta forma, os dados existentes foram avaliados a fim de determinar o fenômeno físico como saída. A primeira solução proposta é que de acordo com a classificação, uma rede neural diferente seja empregada para prever a carga esperada de cada comportamento. A carga final de cada viga é a soma ponderada do resultado de cada uma destas redes, utilizando os graus de ativação gerados pelo sistema neuro-fuzzy como pesos do somatório (Figura 4.4).

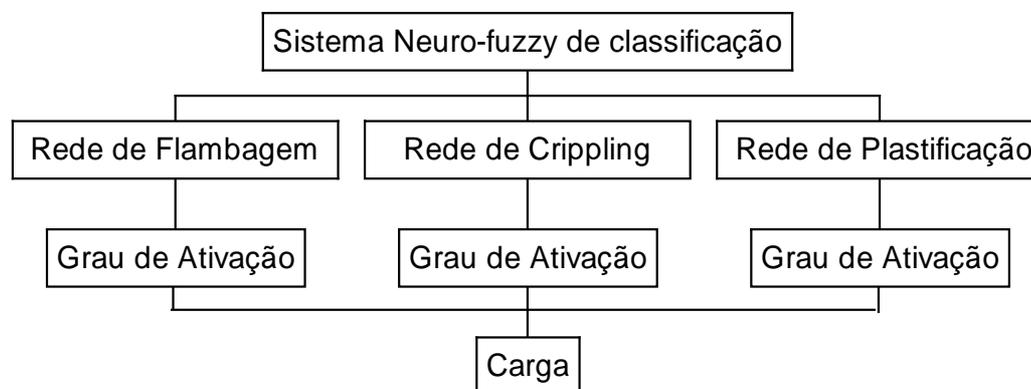


Figura 4.4 – Modelo neuro-fuzzy.

Os dados de treinamento e teste do sistema *neuro-fuzzy* de classificação tem os parâmetros geométricos e de material como entradas, e o fenômeno físico correspondente como saída. Para isso, é necessário avaliar os dados de cargas concentradas existentes com relação ao fenômeno ocorrido.

4.5 A pesquisa dos Dados Bibliográficos

Um novo levantamento bibliográfico foi desenvolvido para viabilizar a utilização destes dados no treinamento do sistema. A partir do trabalho de Roberts & Newark (1997), cada dado experimental [anexo A] foi estudado em sua fonte original para avaliar qual o fenômeno físico atuante na ruína.

Os dados 1-23 do anexo A foram originalmente ensaiados por Bergfelt (Bergfelt & Hovik, 1968) (Bergfelt, 1971). De acordo com observações do autor, todos os dados pertencem a primeira classe – flambagem.

Os dados 24-44 são originários dos trabalhos de Skaloud & Novak (1972) e Skaloud & Drdacky (1975). Segundo os autores “Uma inspeção das figuras abaixo mostra a grande influência da rigidez da mesa na deformação das vigas ensaiadas. Enquanto, no caso de mesas flexíveis, a flambagem da alma e a deformação da mesa estão localizadas próximas a carga concentrada, em mesas rígidas a deformação da alma e a flexão das mesas estão distribuídas praticamente em toda a extensão do painel”. Foi considerado então que as vigas com espessura de mesa inferior a 6,5 mm pertencem à segunda classe – enrugamento (*crippling*), e as demais à primeira classe – flambagem.

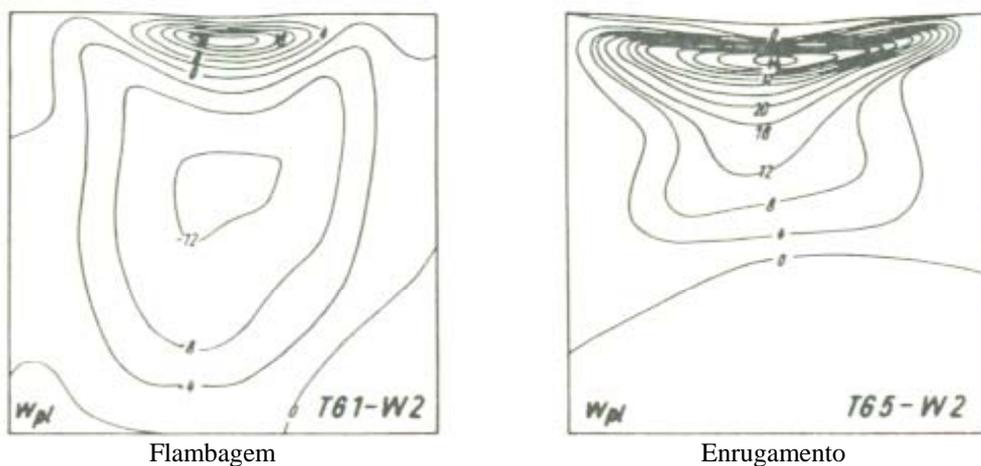


Figura 4.5 – Painéis característicos das vigas ensaiadas TG1 e TG5 (Skaloud & Novak, 1972).

Os dados 45-47 do anexo foram ensaiados por Bagchi & Rockey (1968) e comparados com simulações de elementos finitos. A figura abaixo apresenta a

deformação típica da alma no ponto de aplicação da carga para os três ensaios. Os dados pertencem à primeira classe – flambagem.

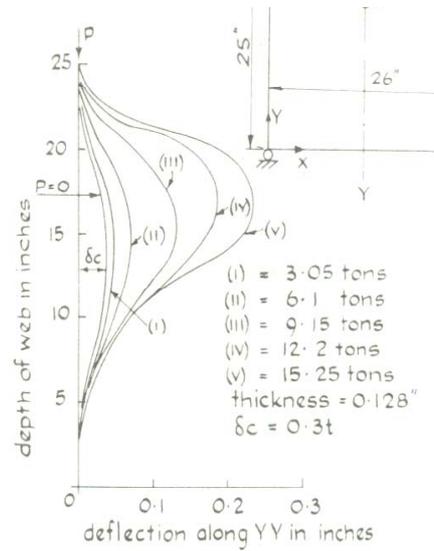


Figura 4.6 – Deformação da alma no ponto de aplicação da carga Bagchi & Rockey, 1975).

Os dados 48-63 foram considerados flambagem a partir das informações obtidas em (Drdacky & Novotny, 1977) e na figura abaixo.

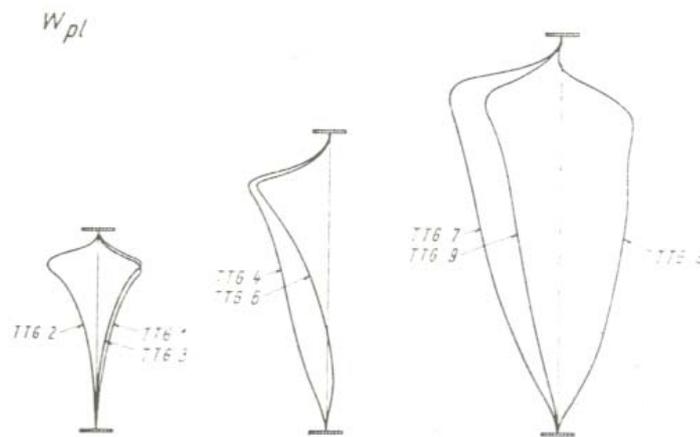


Figura 4.7 – Deformação da alma no ponto de aplicação da carga(Drdacky & Novotny, 1977)).

O trabalho de Bergfelt (1979) fornece o tipo de fenômeno físico ocorrido em 22 ensaios a partir de informações sobre o formato de deformação da seção transversal da alma na área de aplicação da carga e da própria carga experimental da viga quando comparada ao valor previsto para a plastificação. O anexo A

apresenta a classificação, enquanto o anexo B apresenta as figuras referentes a estes e outros ensaios.

Os dados 64-67 foram avaliados por informações do texto e do anexo B. Os dados 64 e 66 foram definidos como flambagem e os dados 65 e 67, apesar de estarem em uma situação intermediária, foram definidos como enrugamento.

Os dados 68-85 são apresentados no Anexo B e foram classificados de acordo com o apresentado no anexo A.

Os dados 86-111 são originários do trabalho de Roberts (1981) e, de acordo com informações tiradas do texto e da Figura 4.8, nos dados de mesa mais flexível ocorreu enrugamento (*crippling*) enquanto que nas vigas de mesas mais rígidas ocorreu um fenômeno intermediário entre enrugamento e flambagem. A classificação adotada é apresentada no anexo A.

No trabalho de Roberts e Markovic (1983) são apresentados os dados 112-124. Estes dados foram considerados como sendo de plastificação e enrugamento. O Anexo A apresenta a classificação utilizada no treinamento.

Os dados 125-142 são resultantes do trabalho de Bergfelt (1983) e são apresentados no Anexo B. A classificação é apresentada no anexo A.

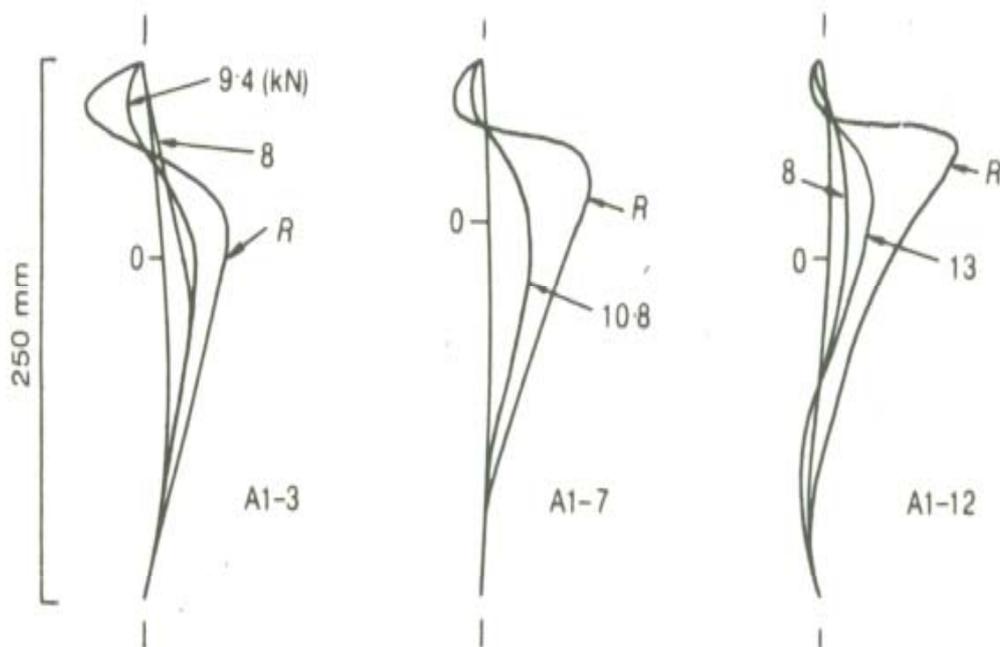


Figura 4.8 – Deformações das almas nos pontos de aplicação da carga - 86 a 111 (Roberts, 1981).

Os dados 143-161 foram retirados do trabalho de Kennedy et al. (1997) e, apesar de serem mais compactos que todos os dados anteriores, somente o dado de número 143 pode ser considerado como pertencente à terceira classe – plastificação, tendo todos os outros dados apresentado problemas de flambagem, sendo assim classificados como de primeira classe.

4.6 A Adaptação do Modelo Proposto aos Dados Bibliográficos

Considerando a pequena concentração de dados da terceira classe (plastificação), o modelo proposto precisou ser reformulado, pois a pequena quantidade de dados desta classe (10 dados experimentais – Anexo A) não permitiria o treinamento de uma rede de previsão específica. Sendo assim, foi adotado um modelo com um sistema de classificação neuro-fuzzy e uma única rede neural de previsão que utilize como entradas os graus de ativação gerados pelo sistema neuro-fuzzy. O novo modelo é apresentado na figura abaixo.

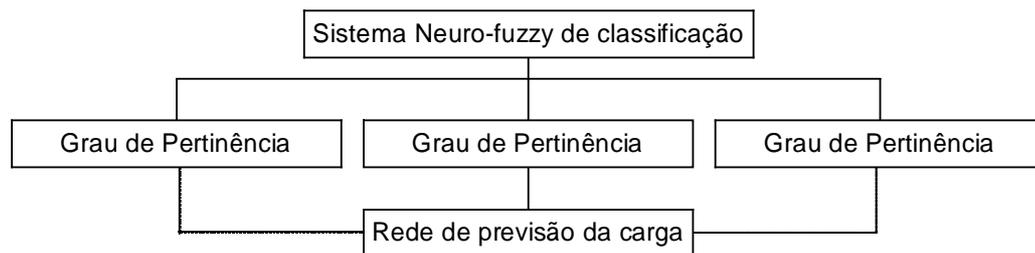


Figura 4.9 – Modelo neuro-fuzzy alterado.

Para treinar o sistema neuro-fuzzy de classificação, foram utilizados os dados apresentados no item anterior e os perfis laminados do anexo C. Estes perfis foram necessários como uma base de dados de plastificação e selecionados por serem compactos e não apresentarem problemas relacionados à instabilidade.

As tensões limite de escoamento adotadas foram de 250 MPa com comprimento carregado de 5 mm e fator de forma do painel de alma (a/h) de 3, correspondendo às condições mais desfavoráveis para a estabilidade dos perfis, garantindo que, mesmo nos piores casos de carregamento, estas vigas não apresentariam problemas de instabilidade.

4.6.1

Sistema Neuro-fuzzy de classificação

Os dados foram divididos em três grupos: um de treinamento (70%), um de validação (20%) e outro de testes (10%). Os parâmetros de entrada adotados no primeiro treinamento foram as oito propriedades geométricas e do material exibidas na Figura 1.5.

Os primeiros treinamentos do sistema resultavam em erros na classificação da ordem de 20 a 25% dos dados de treinamento e validação. Estes erros foram considerados insatisfatórios e foi feita uma nova avaliação dos dados para verificar se uma classificação incorreta de alguns dados poderia estar prejudicando todo o conjunto de treinamento e fazendo com que o sistema aprendesse a partir de exemplos errados. Algumas alterações foram executadas.

- Os dados 1-23 haviam sido classificados todos como flambagem, mas de acordo com uma observação do autor, os dados com espessura de mesa menores que o dobro da espessura da alma apresentavam comportamento de enrugamento, sendo assim os dados 1 e 2 foram alterados.
- Havia também a possibilidade do sistema estar caindo em um mínimo local da função de classificação dos dados. Para evitar este problema, foi alterada a taxa de decomposição do programa. Quanto menor esta taxa, maior o número de regras criadas pelo sistema, atendendo a problemas de interação entre parâmetros mais complexa.
- Foi também considerada a inclusão de novos parâmetros como entrada. Alguns treinamentos mostravam que as tensões limite de escoamento da alma e da mesa eram consideradas mais importantes para a classificação do que a espessura da mesa e outros parâmetros geométricos. Avaliando o conjunto de dados, foi possível constatar que a adoção de valores iguais de tensões limite de escoamento para a maioria dos dados da terceira classe fazia o sistema aprender que este valor era muito significativo para a classificação. Assim, os perfis foram repetidos com tensões limite de escoamento de 350 MPa, fator de forma (a/h) de 1 e comprimento carregado c igual a um quarto da altura da viga.

- Foi inserida a esbeltez e o parâmetro B definido pela equação 2.14 como novas entradas. Este parâmetro foi adotado por ser empregado para definir o limite entre flambagem e plastificação dos dados apresentados em (Kennedy et al., 1997).

Após diversos treinamentos com estas alterações, os erros de classificação foram reduzidos para 5,75% no conjunto de treinamento e 7,41% no conjunto de validação. A taxa de decomposição do programa foi de 0,0015 e o número de regras geradas foi de 377. Os dados de testes foram todos classificados corretamente.

Apesar dos bons resultados, o número de regras gerado estava excessivo quando comparado ao número total de dados, existindo mais de uma regra para cada dado. Desta forma, foi necessário reduzir os erros mesmo com uma taxa de decomposição mais alta, para limitar o número de regras.

Utilizando taxas de decomposição na ordem de 0,01, os erros ficavam ainda em torno de 15%. Uma possibilidade era que os dados intermediários entre um fenômeno físico e outro pudessem estar atrapalhando o treinamento e duas soluções foram aventadas:

- Retirar os dados intermediários do conjunto de treinamento; ou
- Apresentar os dados intermediários ao sistema duas vezes, tendo em cada uma um fenômeno físico diferente como saída.

A primeira solução não foi satisfatória, pois retirava informações significativas do conjunto de treinamento, resultando em falhas no aprendizado dos conjuntos de dados de trabalhos onde havia um maior número de ensaios intermediários e os erros aumentaram para a faixa dos 20%.

A segunda solução se mostrou satisfatória. Os erros de classificação foram reduzidos para 3,7% no conjunto de treinamento e 0% no conjunto de validação. A taxa de decomposição do programa foi de 0,01 e o número de regras geradas foi de 85. Os dados de testes foram todos classificados corretamente. A Figura 4.10 mostra a tela de resultados apresentada pelo programa.

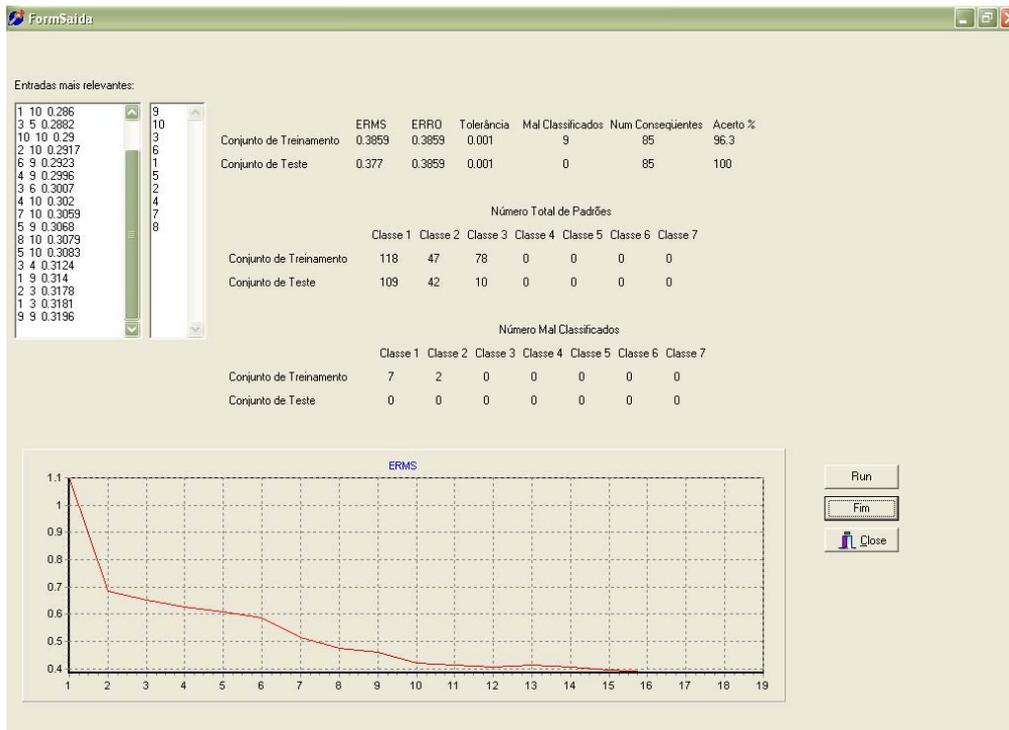


Figura 4.10 – Resultado do treinamento apresentado pelo programa.

4.6.2

Rede de previsão da carga última

Os dados de treinamento e validação da rede empregam os parâmetros geométricos e de material e os graus de ativação como entradas, e a carga última como saída. Os dados utilizados no treinamento são apresentados no anexo A. O programa adotado é o Software NeuralWorks Predict (Neuralware, 1997) para o treinamento e a avaliação das redes. Por permitir a utilização de planilhas do Microsoft Excel para a entrada e saída de dados da rede, o programa fornece maiores possibilidades de investigação das variáveis relevantes, permitindo alterações mais rápidas no conjunto de dados e avaliações gráficas simultâneas a cada rede treinada.

Várias redes foram treinadas variando as opções apresentadas pelo software:

- **Nível de ruído dos dados de treinamento:** O programa trata os dados de forma diferente de acordo com a confiabilidade dos mesmos;
- **Transformação dos dados:** O programa gera novas entradas a partir da transformação de variáveis x em x^2 , $1/x$, etc. É possível optar por uma escala simples ou um nível maior de transformação;

- **Seleção de variáveis:** As variáveis mais importantes permanecem como entradas da rede e as outras são descartadas, de forma a diminuir o número de entradas e melhorar a generalização (Haykin, 1999);
- **Busca da rede:** O programa pode treinar várias redes de arquiteturas diferentes e selecionar a mais adequada. O usuário define a intensidade da busca;
- **Tolerância (%):** O usuário define o erro percentual tolerado para o treinamento da rede;
- **Função de ativação:** Opção entre os diferentes tipos de função de ativação disponíveis (sigmóide, tangente hiperbólica, etc.).

Os primeiros treinamentos foram feitos com os graus de ativação fornecidos pelo sistema neuro-fuzzy inicial de 377 regras e geravam erros máximos da ordem de 100%, compatíveis com os apresentados pela fórmula de Roberts (2.12). Foi verificado que os erros mais significativos eram referentes aos dados de espessura de alma inferior a 1 mm e estes dados foram retirados do conjunto de treinamento por não serem considerados confiáveis, considerando-se a dificuldade de realização de ensaios experimentais precisos com vigas de aço destas dimensões. O erro máximo foi reduzido para 70%.

Foi aventada a possibilidade de inserção de novas colunas de entradas, principalmente no que se refere aos parâmetros combinados, como esbeltez, fator de forma do painel de alma e fórmulas com as de Roberts (2.12) e Lyse & Godfrey (2.1). Sabendo-se que a espessura da alma ao quadrado influencia diretamente o resultado, uma nova coluna de entrada foi inserida (t_w^2). Apesar da rede ser capaz de estabelecer esta relação apenas pelo fornecimento de t_w , o tempo e o número de dados necessários ao treinamento tendem a diminuir.

As características da melhor rede selecionada são apresentadas na Tabela 4.4 e comparadas com a fórmula de Roberts (2.12). As entradas utilizadas foram os oito parâmetros apresentados na Figura 1.5, os graus de ativação a cada fenômeno físico, o parâmetro B (equação 2.14), a fórmula de Roberts (2.12), a espessura da alma ao quadrado, o fator de forma do painel de alma e a esbeltez da alma.

Novos treinamentos foram feitos com os graus de ativação fornecidos pelo sistema neuro-fuzzy de 85 regras e os resultados apresentaram uma melhora significativa.

Tabela 4.4 – Características da Primeira Rede Selecionada.

	Rede	Roberts
Entradas	16	-
Processadores na Camada escondida	16	-
Saídas	1	-
Tolerância (%)	25	-
Função de Ativação	Sigmóide	-
Nível de Ruído	Dados limpos	-
Transformação de Dados	Superficial	-
Seleção de Variáveis	Nenhuma	-
Busca da Rede	Exaustiva	-
Erro percentual máximo	28,00%	92,41%
Desvio padrão	8,60	16,38
Erro Percentual médio absoluto	6,47%	11,59%
Dados com erro inferior a 5%	54,02%	28,73%
Dados com erro entre 5% e 10%	22,99%	28,16%
Dados com erro entre 10% e 15%	13,79%	16,67%
Dados com erro entre 15% e 20%	4,02%	14,37%
Dados com erro entre 20% e 25%	4,60%	6,32%
Dados com erro entre 25% e 35%	0,57%	2,87%
Dados com erro entre 35% e 65%	-	1,72%
Dados com erro entre 65% e 95%	-	1,15%
Percentual de Treinamento-Validação - Testes	70-20-10	-

As características da melhor rede selecionada são apresentadas na Tabela 4.5 e comparadas com as fórmulas de Roberts e da Norma Canadense de 2001 (Figura 4.11). As entradas utilizadas foram os oito parâmetros apresentados na Figura 1.5, os graus de ativação a cada fenômeno físico, o parâmetro B (equação 2.14), a fórmulas de Roberts a e a esbeltez da alma.

Os capítulos 5 e 6 apresentam uma avaliação dos resultados da rede neural treinada neste capítulo e uma análise paramétrica envolvendo os fenômenos físicos e a variação de carga.

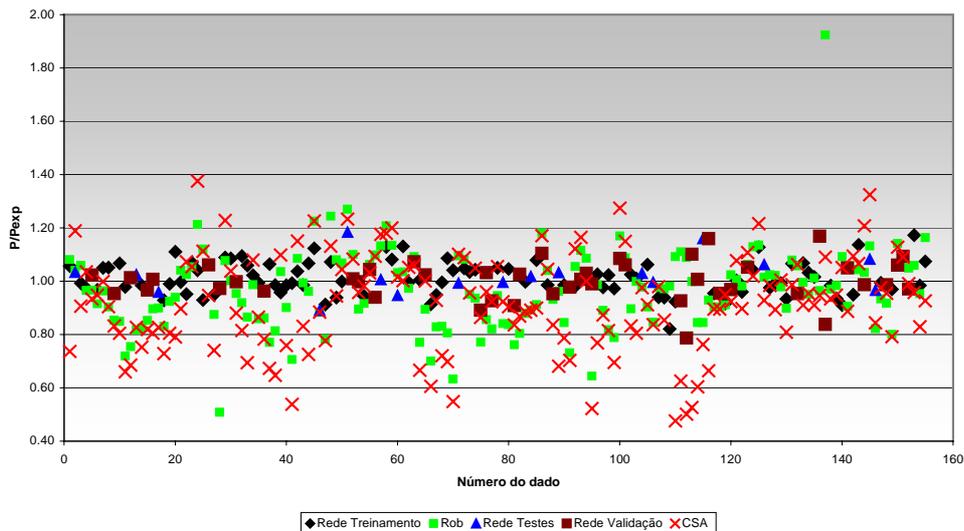


Figura 4.11 – Comparação da Rede com as fórmulas de Roberts e da Norma Canadense.

Tabela 4.5 – Características da Melhor Rede Seleccionada.

	Primeira Rede	Rede Seleccionada	CSA	Roberts
Entradas	16	14	-	L-
Processadores na Camada escondida	16	8	-	-
Saídas	1	1	-	-
Tolerância (%)	25	20	-	-
Função de Ativação	Sigmóide	Sigmóide	-	-
Nível de Ruído	Dados limpos	Dados limpos	-	-
Transformação de Dados	Superficial	Superficial	-	-
Seleção de Variáveis	Nenhuma	Nenhuma	-	-
Busca da Rede	Exaustiva	Exaustiva	-	-
Erro percentual máximo	28,00%	21,33%	67,45%	92,41%
Desvio padrão	8,60	6,67	18,39	16,38
Erro Percentual médio absoluto	6,47%	5,17%	15,44%	11,59%
Dados com erro inferior a 5%	54,02%	51,61%	17,24%	28,73%
Dados com erro entre 5% e 10%	22,99%	34,84%	25,86%	28,16%
Dados com erro entre 10% e 15%	13,79%	7,10%	13,79%	16,67%
Dados com erro entre 15% e 20%	4,02%	5,81%	15,52%	14,37%
Dados com erro acima de 20%	5,17%	0,64%	27,58%	12,06%
Percentual de Treinamento-Validação - Testes	70-20-10	70-20-10	-	-