



# **Comportamento de vigas de aço sujeitas a cargas concentradas através de técnicas de inteligência computacional**

---

**Elaine Toscano Fonseca  
Pedro C G S Vellasco**

# Escopo da Apresentação

---

- Introdução
  - Revisão Bibliográfica
  - Inteligência Computacional
  - A Inteligência Computacional no Fenômeno de Cargas Concentradas
  - Análise Paramétrica do Fenômeno Físico
  - Análise Paramétrica da Carga Crítica
  - Considerações Finais
-

# Motivação

---

- Fórmulas de previsão da carga - erros superiores a 20%;
  - Experimentos na literatura insuficientes para uma análise paramétrica completa;
  - Novos resultados experimentais - tempo e dinheiro;
  - Resultados via método dos elementos finitos ainda apresentam diferenças;
  - Inteligência Computacional – novas técnicas para o estudo de problemas complexos.
-

# Revisão Bibliográfica

Kennedy (1997):

31 dados experimentais;

Adoção do parâmetro B.

$$B = (c + 9t_f)t_w \sqrt{\frac{\sigma_y}{E}}$$

Norma Canadense (2001):

Menor de dois valores.

$$P_f = 0,8t_w (c + 10t_f) \sigma_y^w$$

$$P_f = 1,16t_w^2 \sqrt{\sigma_y^w E}$$

# Revisão Bibliográfica

Eurocode (1997):

Única verificação para os três fenômenos.

$$P = \frac{P_y \chi}{1.1}$$

$$P_y = \sigma_w t_w I_y$$

$$I_y = c + 2t_f \left(1 + \sqrt{m_1 + m_2}\right)$$

$$m_1 = \sigma_f b_f / \sigma_w t_w$$

$$m_2 = 0.02 \left(h / t_f\right)^2$$

$$k_F = 6 + 2(h / a)$$

$$\chi = \frac{0.5}{\sqrt{\frac{P_y}{P_{cr}}}} \leq 1$$

$$P_{cr} = k_F \left(\pi^2 E / 12(1 - \nu^2)\right) \left(\frac{t_w^3}{h}\right)$$

# Inteligência Computacional

---

Conjunto de técnicas inspiradas na Natureza para o desenvolvimento de sistemas inteligentes, que imitam características do comportamento humano. Ex.:

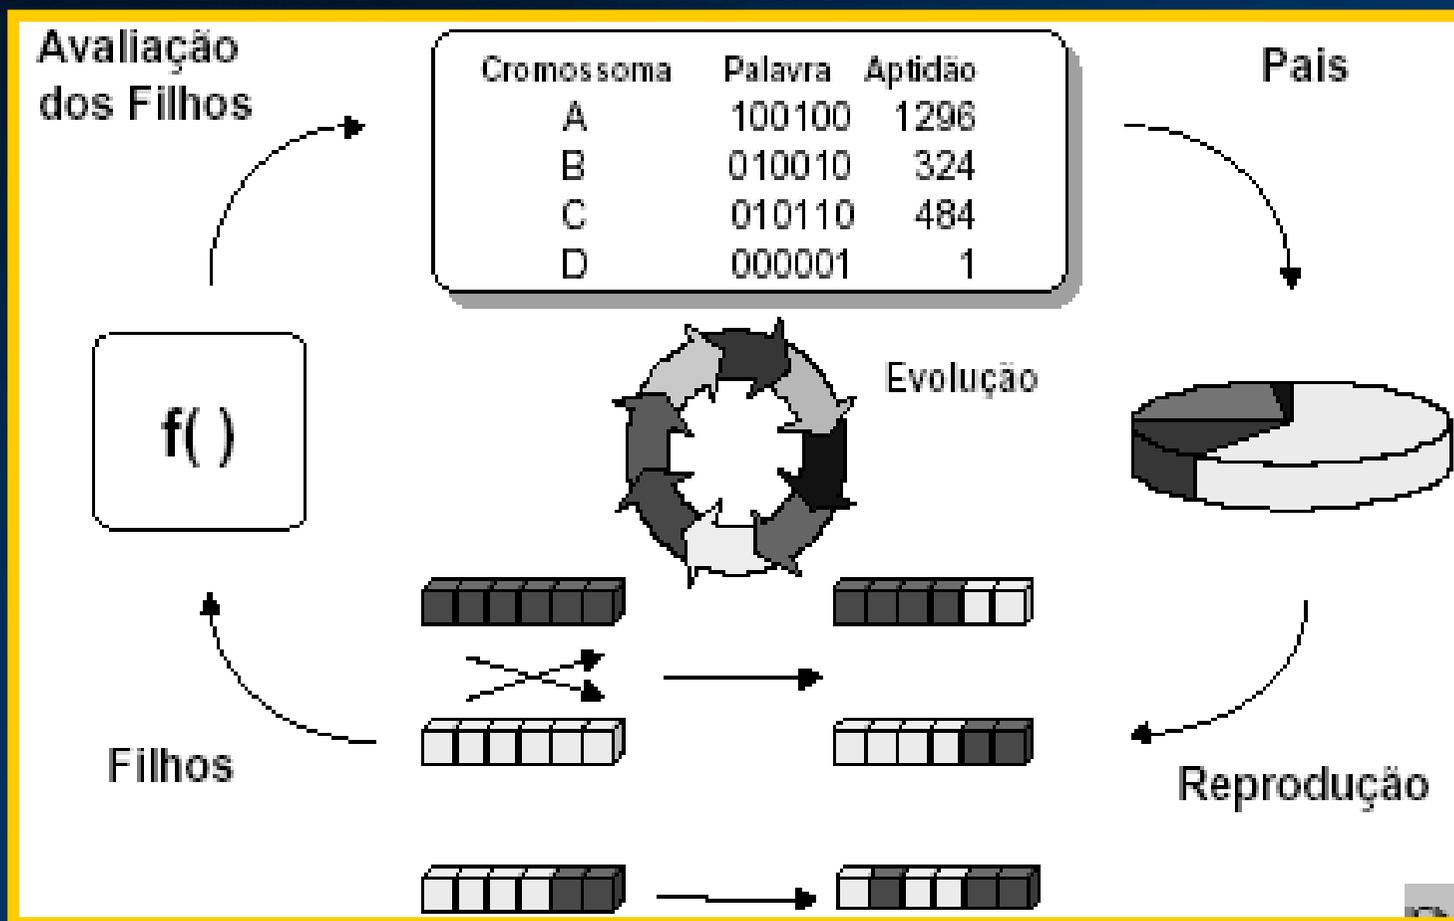
- Aprendizado;
  - Raciocínio;
  - Evolução;
  - Adaptação.
-

# Algoritmos Genéticos

---

- Algoritmos de busca inspirados no princípio Darwiniano de evolução;
  - Combinam sobrevivência do mais apto e cruzamento aleatório de informação;
  - Adaptativo - informação corrente influencia a busca futura;
  - Paralelo - várias soluções consideradas a cada momento;
  - Problemas Complexos - de difícil formulação matemática ou com grande espaço de busca (grande número de soluções).
-

# Ciclo do Algoritmo



# Aplicações

---

- Alocação de salas de aula;
  - Otimização de percurso;
  - Otimização de tabelas de jogos;
  - Controle de fluxo de caixa;
  - Otimização de projeto de galpões industriais;
  - Otimização de ligações estruturais em aço;
  - Otimização de fórmulas de previsão de carga crítica.
-

# Redes Neurais

---

Inspiradas na estrutura do cérebro para apresentar características humanas, tais como:

- Aprendizado por experiência;
  - Generalização de novos exemplos;
  - Abstração;
  - Associação entre padrões diferentes.
-

# Aplicações em Estruturas

---

- Modelagem da capacidade de colunas esbeltas de concreto;
  - Resistência Sísmica de estruturas;
  - Classificação, identificação e cálculo de ligações semi-rígidas;
  - Previsão da capacidade de ligações no eixo de menor inércia.
-

# Utilização das redes neurais para a previsão da carga crítica

- Bons resultados na previsão da carga, apesar dos 3 tipos de fenômenos não terem sido considerados separadamente;



# Propriedades Geométricas e do Material

---

- Espessura da Alma;
  - Espessura da Mesa;
  - Largura da Mesa;
  - Comprimento do painel de alma;
  - Comprimento uniformemente carregado;
  - Altura da alma;
  - Tensões de escoamento da mesa e da alma;
  - Espessura da alma ao quadrado.
-

# Características das Redes

<b>Rede Neural</b>	<b>Classificação</b>	<b>Faixa 1</b>	<b>Faixa 2</b>	<b>Faixa 3</b>
<b>Tolerância (%)</b>	5	20	20	17
<b>Erro percentual máximo</b>	-	14.28	12.96	11.16
<b>Desvio padrão</b>		5.20	3.48	4.47
<b>Erro Percentual médio absoluto</b>	-	4.08	2.75	4.68
<b>Dados com erro inferior a 5%</b>	100%	69.6%	86.7%	60.7%
<b>Dados com erro entre 5% e 10%</b>	-	24.1%	8.9%	32.1%
<b>Dados com erro entre 10% e 15%</b>	-	6.3%	4.4%	7.2%
<b>Percentual de Treinamento-Testes</b>	70-30	70-30	70-30	70-30

Treinamento e divisão das redes baseados na carga e não no comportamento estrutural.

# Lógica Nebulosa (Fuzzy Logic)

---

Capaz de incorporar tanto o conhecimento objetivo (a partir de dados numéricos) quanto o conhecimento subjetivo (a partir de informações lingüísticas).

Os elementos pertencem a cada conjunto com diferentes graus.

---

# Fuzzy – Aplicações

---

- Controle de aeronaves, metrô, etc;
  - Ajuste de imagem de TV;
  - Ajuste de foco;
  - Controles de temperatura, velocidade posição, etc.
  - Detecção de danos em estruturas;
  - Cálculo do traço do concreto;
  - Seleção de guindastes;
  - Avaliação da performance, durabilidade e capacidade de carga de pontes de concreto.
-

# Modelos Neuro-fuzzy Hierárquicos

---

- Combinam a capacidade de aprendizado das Redes Neurais com o poder de interpretação lingüístico dos sistemas de inferência fuzzy.
  - são capazes de extrair regras de conhecimento a partir de um conjunto de dados.
  - particionamento recursivo que pode ser representada por uma árvore binária que ilustra as sucessivas sub-divisões do espaço de entrada.
  - taxa de decomposição - limita o número de partições e, conseqüentemente, o número de regras.
  - descobre a relação entre os dados para prever a classe de um padrão desconhecido.
-

# Algoritmos genéticos na geração de uma nova fórmula

---

- Impossibilidade da utilização da técnica de regressão simbólica (ausência de um programa);
  - Possibilidade da otimização de coeficientes e potências de fórmulas da bibliografia;
  - Verificação da possibilidade de utilização de uma única fórmula.
-

# Resultados - GA

$$P_f = \left(\frac{t_w}{h}\right)^{K1} \left[ t_w^{K2} (E\sigma_y^w)^{K3} \left(\frac{t_f}{t_w}\right)^{K4} (K5 + K6 c_e^{K7} t_w^{K8} t_f^{K9} h^{K10} b_w^{K11}) \right] + K12 \left(\frac{t_w}{h}\right)^{K13} t_w \sigma_y^w (c + K14 t_f)$$

$$P_f = \left(\frac{t_w}{h}\right)^{0.001} t_w^2 (E\sigma_y^w)^{0.5} \left(\frac{t_f}{t_w}\right)^{0.4} \left[ 0.8 + 0.12(c + 1.75 t_f)^{3.3} \frac{h^{0.95}}{t_w^{0.25} t_f^{0.75} a^{3.25}} \right] + 0.2 \left(\frac{t_w}{h}\right)^{0.06} t_w \sigma_y^w (c + 1.75 t_f)$$

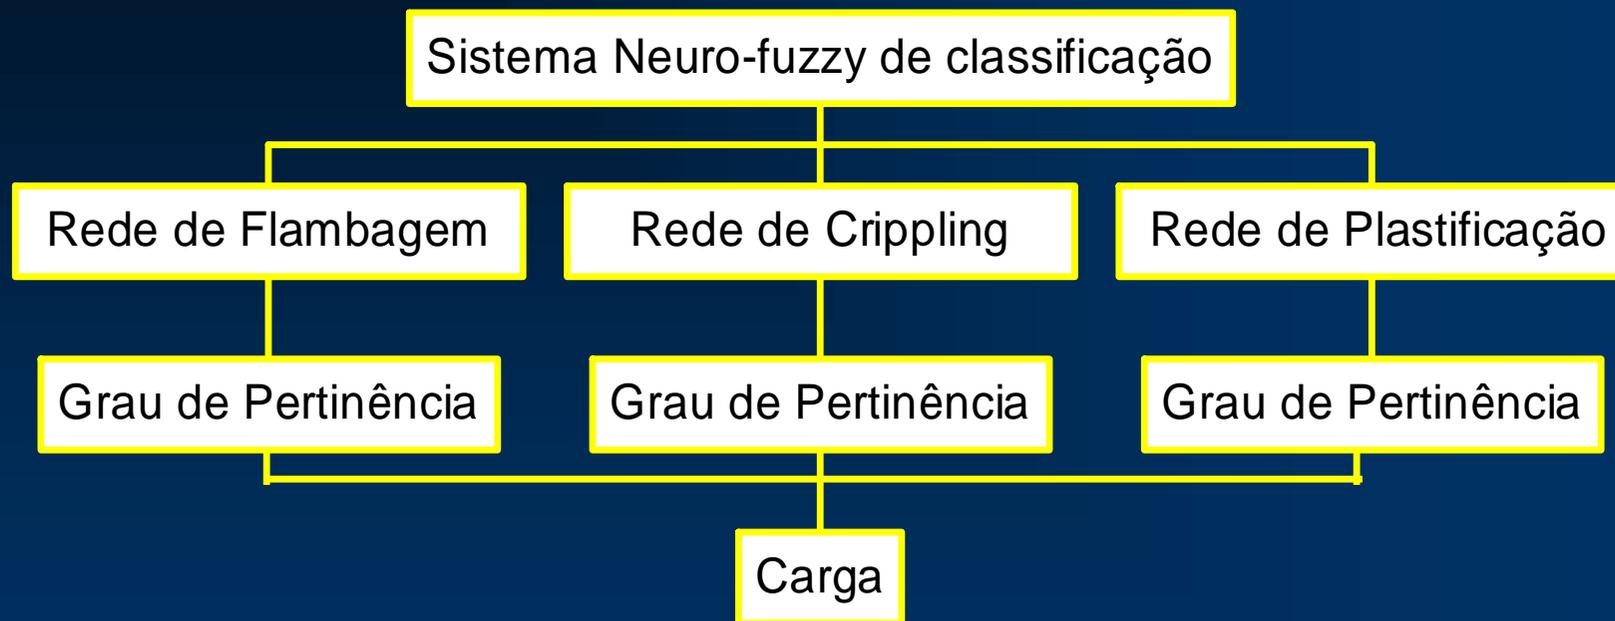
	Fórmula GA	Roberts	Bergfelt	Lyse&Godfrey
erro máximo	30.459	85.19298	567.0161	117.0123023
erro médio	13.111	12.82556	35.65974	43.22098392

# Sistema de Classificação Neuro-fuzzy

---

- Apesar dos bons resultados, a matemática intrínseca das redes neurais não é visível;
  - A lógica nebulosa permite uma classificação mais suave, baseada nos graus de pertinência.
  - Possibilidade de prever o comportamento estrutural das vigas;
  - Classificação baseada no comportamento estrutural e não na faixa de carga;
-

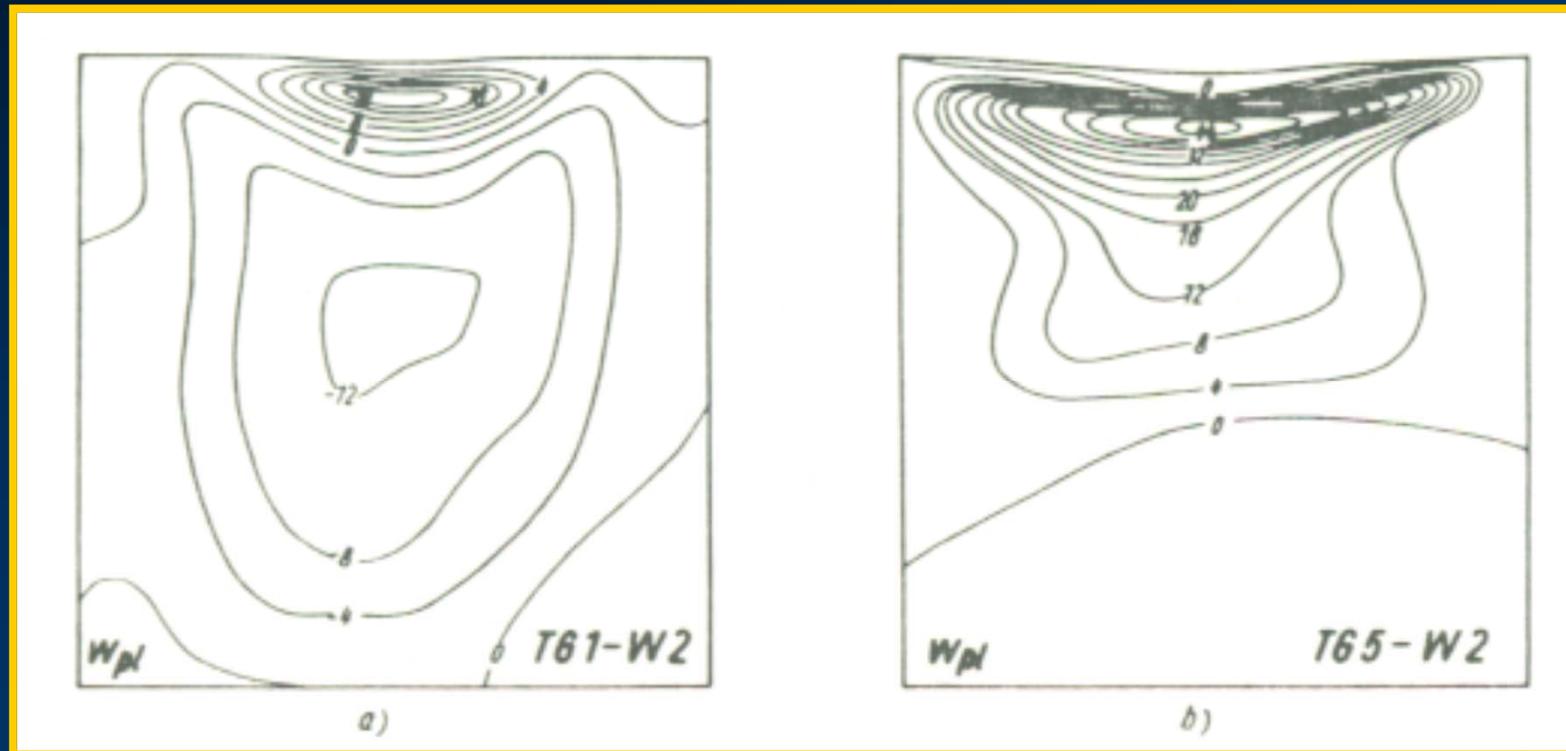
# Sistema Neuro-fuzzy proposto



- Necessidade da avaliação do fenômeno físico dos dados bibliográficos.

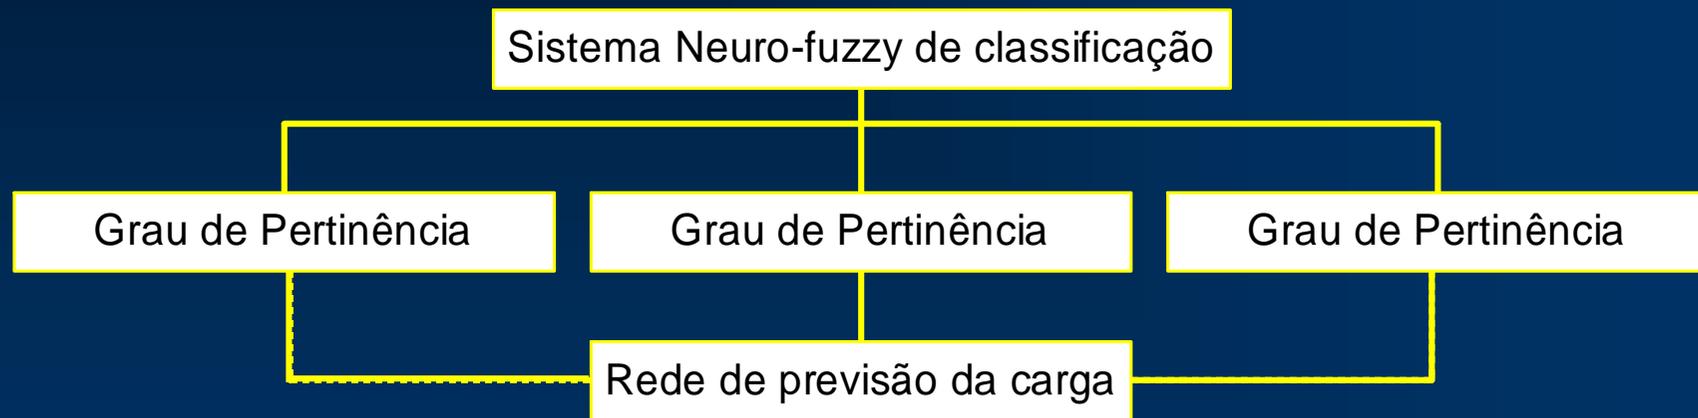
# Pesquisa dos dados bibliográficos

- Exemplo [SKAL72]:



# Modelo Neuro-fuzzy alterado

- Poucos dados bibliográficos de plastificação.



# Sistema de classificação

---

3 grupos: treinamento (70%), validação (20%) e testes (10%).

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.

---

# Sistema de classificação

---

Apresentar os dados intermediários ao sistema duas vezes, tendo em cada uma um fenômeno físico diferente como saída.

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.

---

# Rede Neural de previsão

---

os dados de espessura de alma inferior a 1 mm foram retirados do conjunto de treinamento;

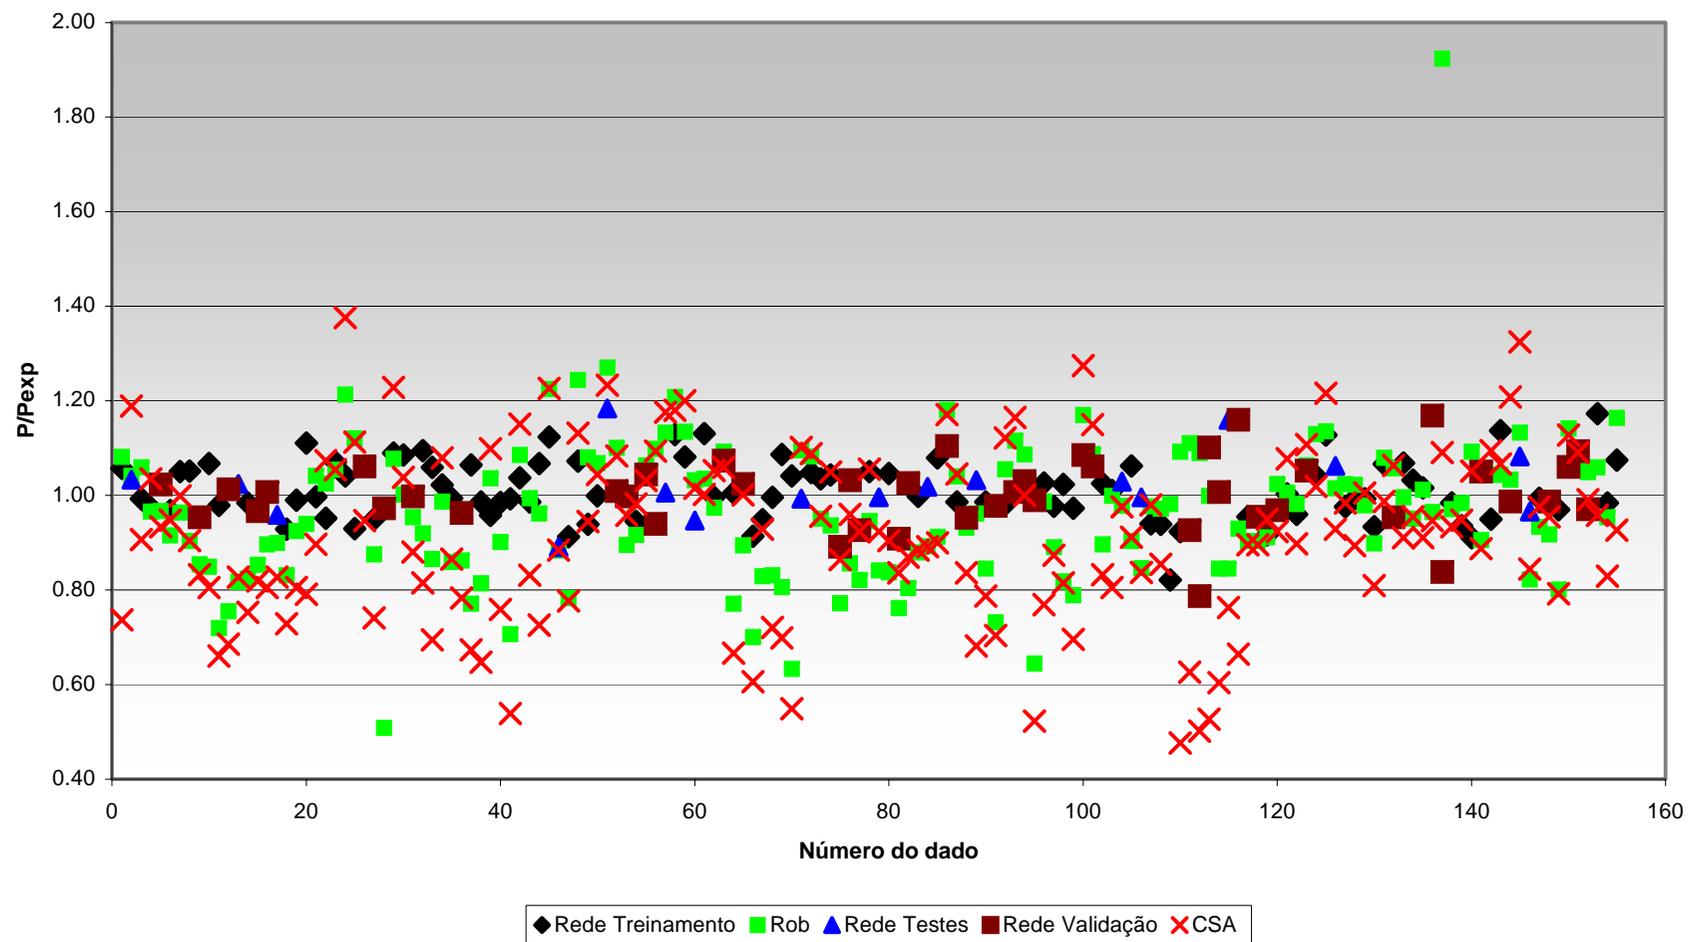
inserção de parâmetros combinados como entradas,

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

As entradas utilizadas foram os oito parâmetros apresentados na Figura 3.4, os graus de ativação a cada fenômeno físico, o parâmetro B (equação 2.14), a fórmulas de Roberts a e a esbeltez da alma.

---

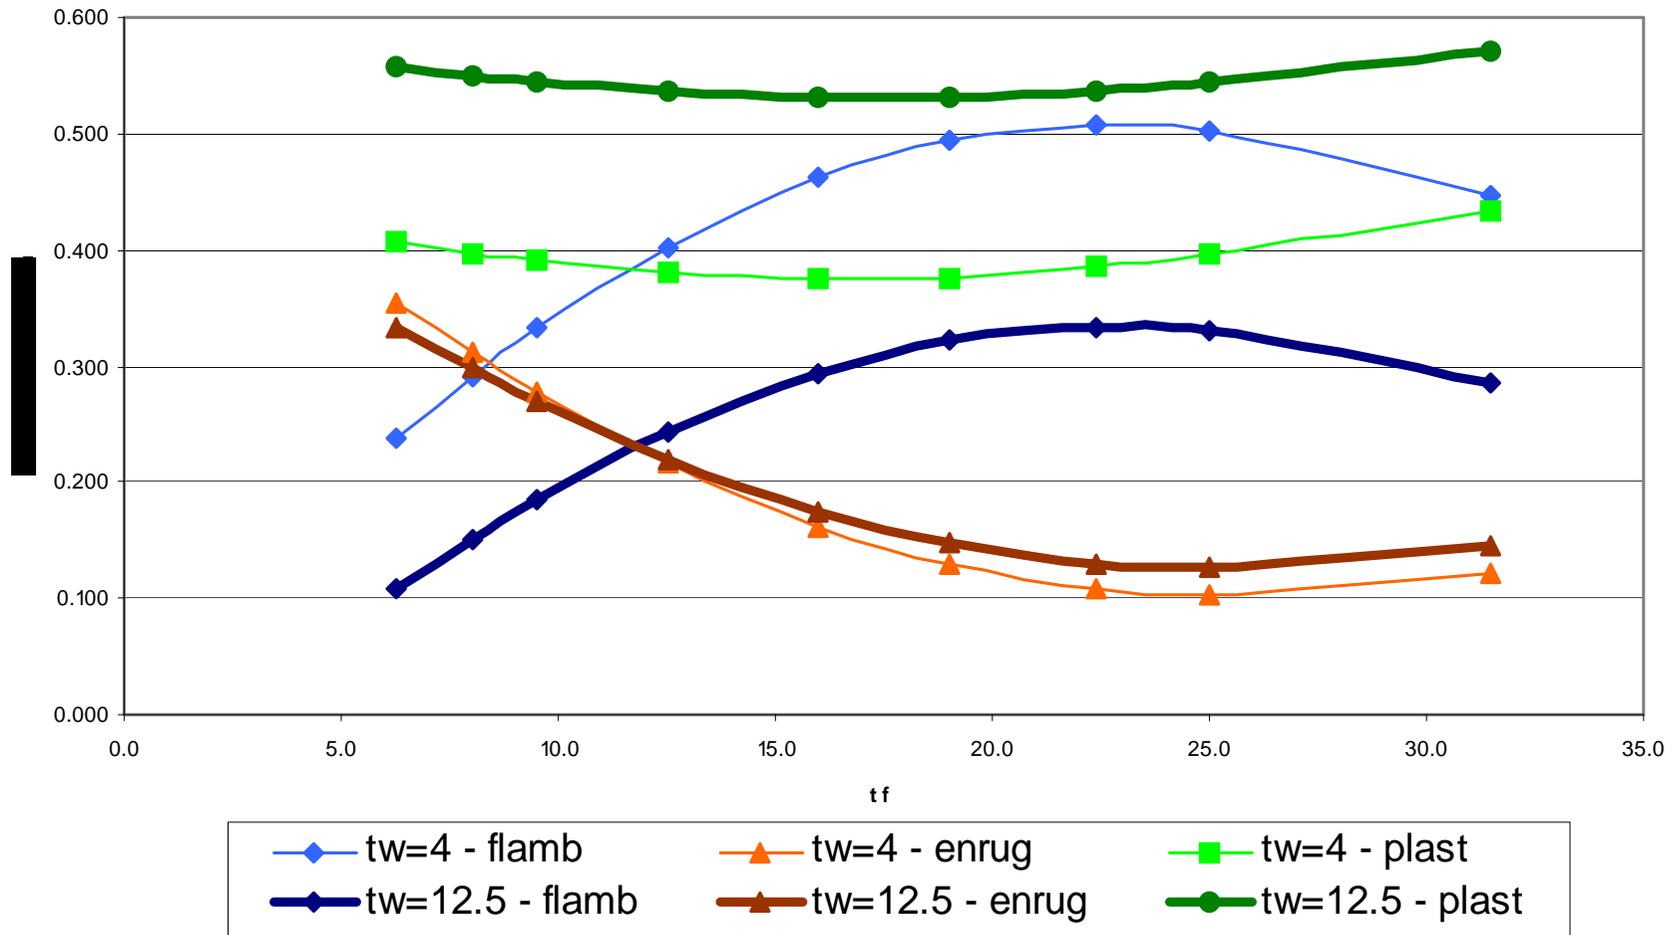
# Rede Neural de previsão



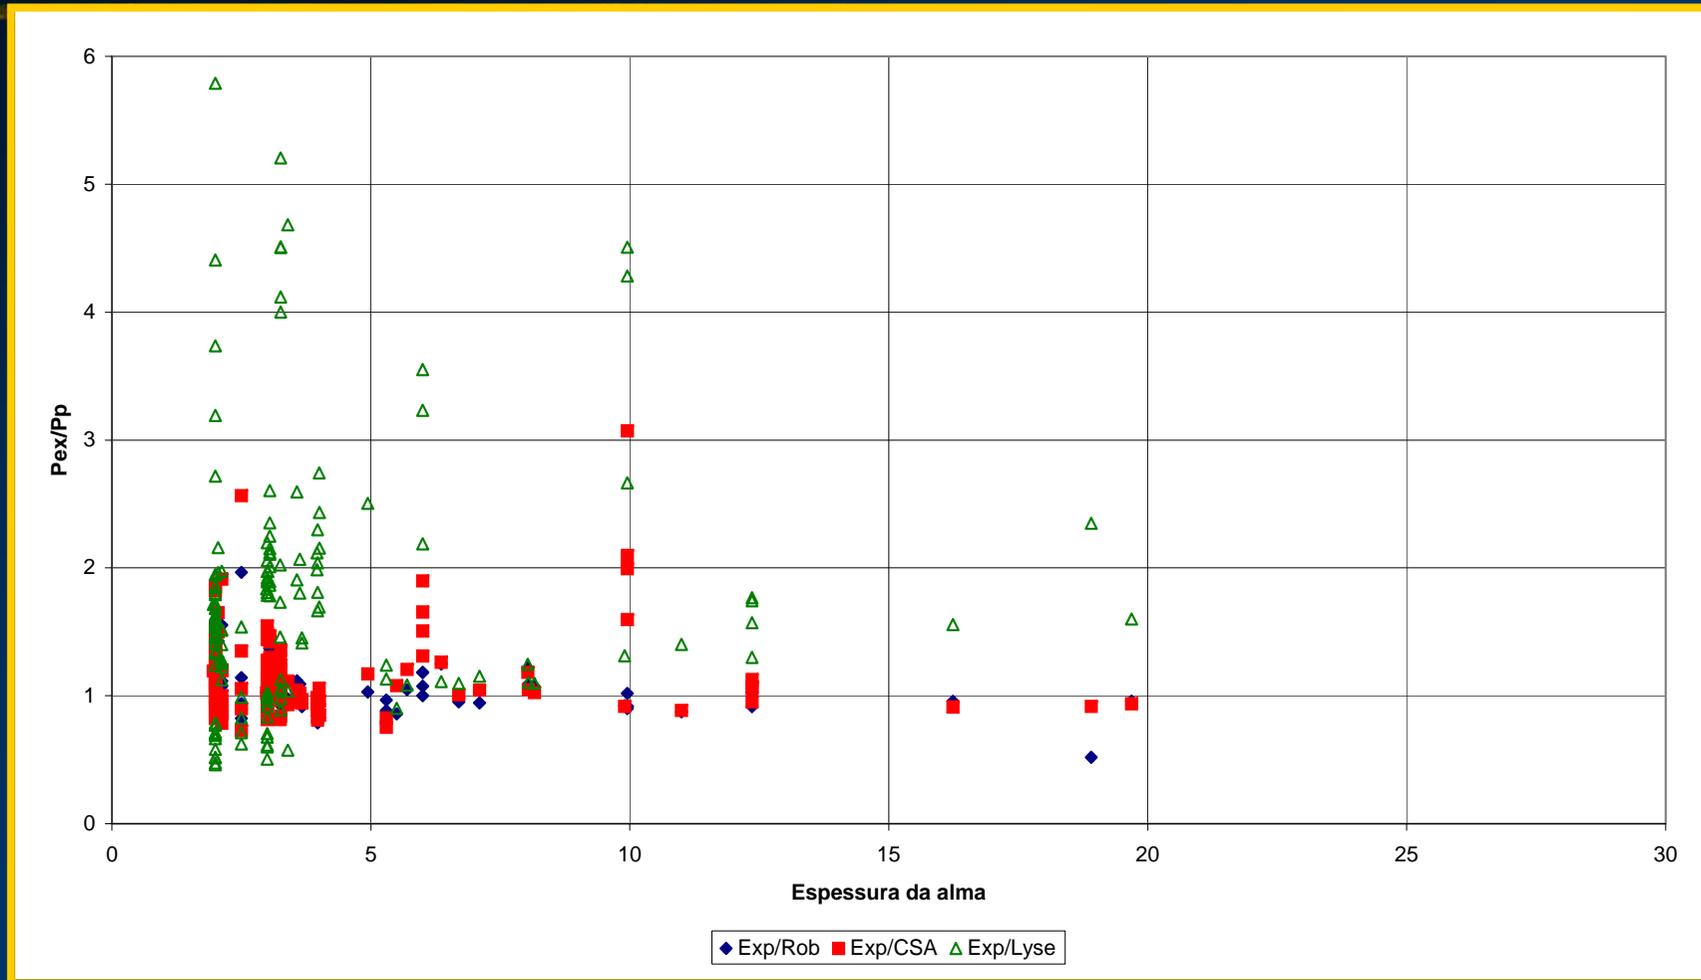
# Análise Paramétrica do Fenômeno Físico e Carga Crítica

# 76 análises

<b>h</b>	<b>b<sub>f</sub></b>	<b>c</b>
375	170	37,5

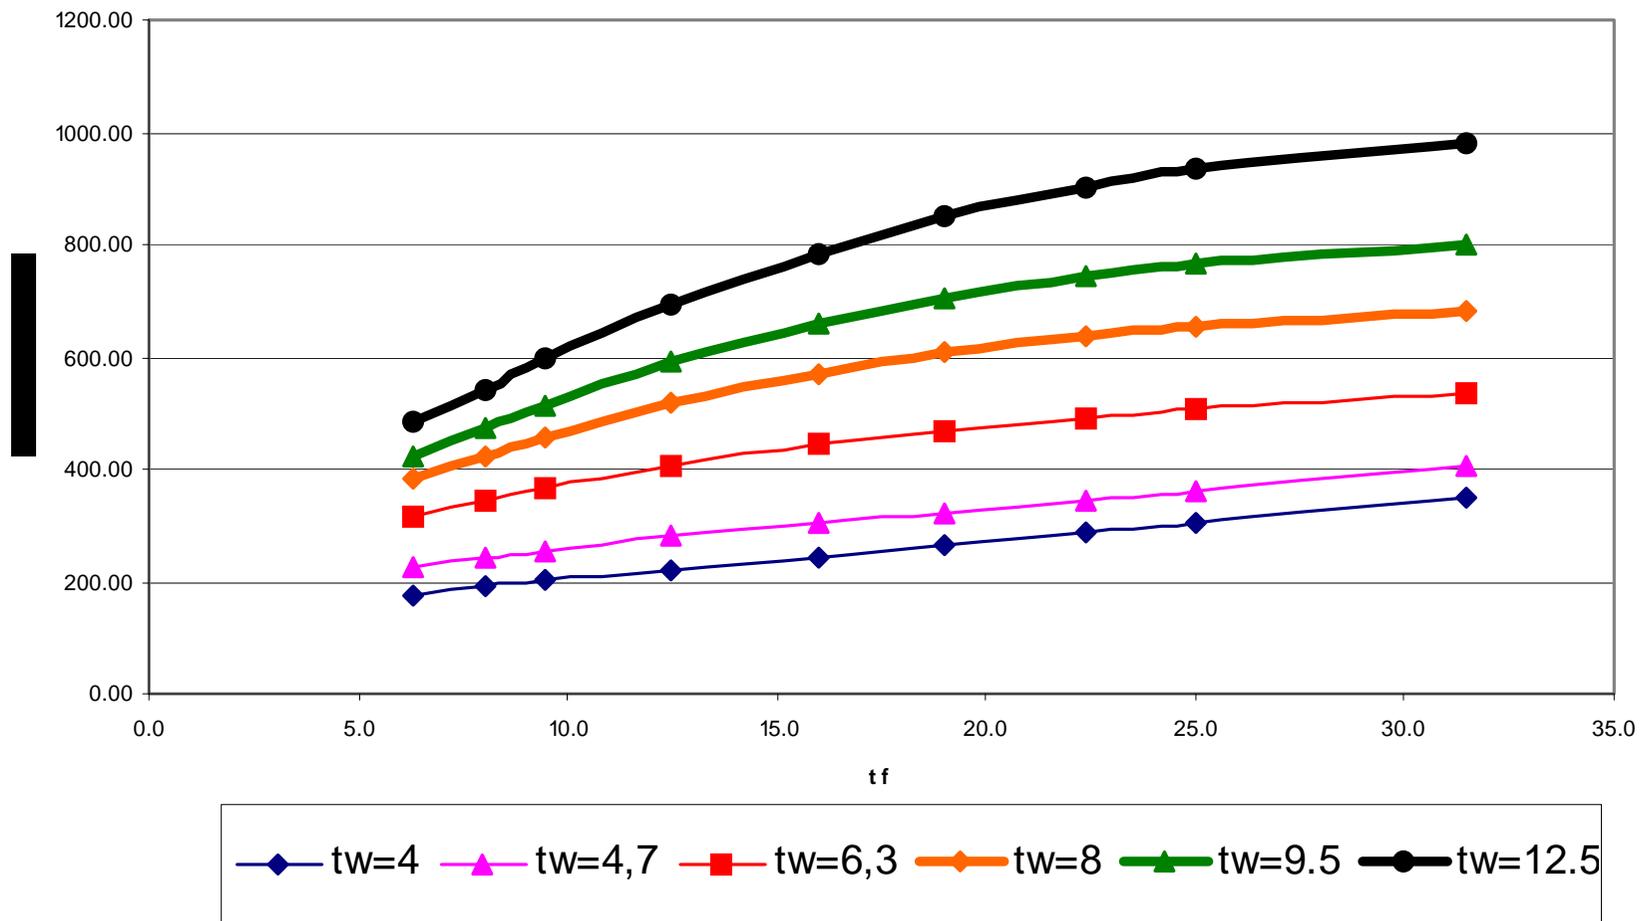


# Avaliação dos resultados



# 62 análises

h	b <sub>f</sub>	c
375	170	37,5



# Conclusões – G.A.

---

- Fórmula otimizada com erros inferiores aos apresentados pelas fórmulas de projeto existentes;
  - Fórmula empírica;
  - Apesar das restrições na forma - resultados satisfatórios, confirmando as vantagens da utilização de uma única fórmula de projeto que estabeleça limites mais graduais entre os comportamentos estruturais;
  - Erros encontrados superiores aos fornecidos pelas redes neurais apresentadas em [FONS99b];
  - O erro máximo (30,45%) foi inferior a todas as outras fórmulas (85,19% na equação 2.12), redução dos fatores de segurança.
-

# Conclusões – Neuro-fuzzy

- a adoção de valores iguais de tensões limite de escoamento para a maioria dos dados da terceira classe fez o sistema aprender erroneamente 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 ( $a/h$ ) igual a 1 e um comprimento carregado  $c$  igual a um quarto da altura da viga;
- o número de regras criadas pelo sistema está diretamente relacionado à capacidade de generalização e à complexidade da iteração entre parâmetros de cada fenômeno estudado. A taxa de decomposição de regras do programa foi um fator importante para o equilíbrio entre o aprendizado e a generalização;
- a esbeltez e o parâmetro  $B$  definido pela equação 2.14 se mostraram importantes na determinação do fenômeno físico, uma vez que a utilização destes parâmetros como novas entradas melhorou o desempenho do sistema;

# Conclusões – Rede neural

- Os dados experimentais com espessura de alma de 0,99mm foram descartados do conjunto de treinamento, devido à dificuldade da realização de ensaios experimentais de perfis com estas características geométricas. Este procedimento reduziu o erro percentual máximo significativamente, excluindo dados excessivamente ruidosos que tendiam a prejudicar o treinamento.
- A utilização da esbeltez, da fórmula de Roberts (2.12) e do parâmetro B definido pela equação 2.14 como entradas melhoraram o aprendizado da rede neural de previsão, mostrando que a apresentação direta de parâmetros combinados tende a melhorar o desempenho das redes neurais em problemas com poucos dados e grande quantidade de parâmetros.
- Os erros de previsão se mostraram pequenos quando comparados às fórmulas de projeto existentes. A fórmula de Roberts, no entanto, quando comparada as outras fórmulas, se mostrou a mais adequada

# Conclusões – Fenômeno físico

- Em almas mais esbeltas a flambagem é dominante, enquanto a plastificação é mais evidente em almas mais espessas ou quando as mesas são mais rígidas;
- o enrugamento é mais comum em mesas mais flexíveis;
- a variação da largura da mesa é pouco significativa;
- em mesas mais finas, a largura da mesa aumenta ligeiramente a ocorrência de enrugamento, diminuindo a ocorrência de flambagem, para cargas em um comprimento carregado menor, e as chances de plastificação em comprimentos carregados maiores;
- uma altura maior diminui as chances de plastificação e aumenta os problemas de instabilidade, principalmente o grau de ativação de enrugamento em mesas mais estreitas e almas mais finas;
- a espessura da mesa exerce grande influência no fenômeno físico,

# Conclusões – Fenômeno físico

- em vigas de mesas mais finas e comprimentos carregados maiores, a flambagem predomina, enquanto para cargas mais concentradas, a plastificação da região é o fenômeno dominante;
- um comprimento carregado maior em almas mais finas aumenta as chances de flambagem global, pois aumenta a distribuição da carga em uma área de alma maior, reduzindo a plastificação e o enrugamento;
- a variação da espessura da mesa é menos significativa para o fenômeno físico em vigas de comprimentos carregados maiores e grandes alturas (mais esbeltas), onde a flambagem global predomina;
- o aumento da altura e conseqüente aumento da esbeltez também favorecem a flambagem global;
- em vigas de almas e mesas mais espessas e carga mais distribuída, o aumento da altura aumenta ligeiramente o grau de ativação de plastificação;

# Conclusões – Carga crítica

- a influência da espessura da mesa na carga é maior em vigas de almas mais espessas;
- nos casos de plastificação há uma tendência da carga a continuar subindo com o aumento da espessura da mesa, enquanto que para os outros casos a carga tende a se estabilizar a partir de valores mais significativos desta espessura;
- nas vigas mais esbeltas e de almas mais finas a influência da espessura da mesa se mostra menor;
- um aumento na largura da mesa aumenta ligeiramente a carga crítica das vigas;
- em todos os casos a espessura da mesa aumenta ligeiramente o valor da carga, no entanto, verifica-se que em almas mais finas a altura se torna mais significativa que a espessura da mesa para comprimentos carregados maiores, enquanto em almas mais espessas a altura e a

# Conclusões – Carga crítica

- o aumento da altura da viga implica diretamente no aumento da esbeltez, mas também influi na redução do fator de forma do painel de alma ( $a/h$ ) e da relação entre o comprimento carregado e a altura ( $c/h$ ), ocasionando grandes variações no fenômeno físico. Isto também explica a não-linearidade do decréscimo da carga em função do aumento da altura;
- em vigas de alma e mesas mais espessas, o aumento da altura aumenta o momento de inércia e conseqüentemente a carga crítica;
- o aumento da altura provoca uma redução da capacidade de carga quando as almas são mais finas (maior esbeltez);
- o aumento do fator de forma provoca uma pequena redução da carga crítica, que tende a ser mais significativa para fatores de forma entre 1 e 2;
- há um aumento da carga em função do aumento do comprimento