

Recuperabilidade de Automóveis pela Análise da Coluna da Carroçaria através de Redes Neurais Artificiais

Walter Xanthopulo^{1,2}, Weber Martins^{1,3}

¹Laboratório PIRENEUS,

Escola de Engenharia Elétrica, Universidade Federal de Goiás

²Coordenação de Análise de Sistemas – Universidade Salgado de Oliveira

²Mestrado em Psicologia, Universidade Católica de Goiás

Goiânia, GO, Brasil.

E-mails: walter, weber@pireneus.eee.ufg.br

Abstract

This paper describes a methodological study for applying technology based on neural networks to the assessment and classification of deformations in crashed cars. Generally, this study applies to every material that obeys the Hook Law. From this study, a procedure could be developed by the computation of deviations of car columns with respect to the standard (brand new) one in order to make it possible to infer the recuperability state of the car.

Some simulation results (using Multilayer Perceptrons with backpropagation) are shown and clearly demonstrate that neural networks are a promising technique to cope with similar situations.

equipamento a ela ligado. Seja ainda pelo elevado nível técnico do pessoal envolvido nestas medições. O desenvolvimento de técnicas independentes, não diretamente aplicadas ao material, é altamente desejável. Automatizar o processo de monitoramento, com a aplicação de técnicas computadorizadas pode ser um fator de importância relevante em termos de precisão e economia. Redes neurais artificiais, por suas características de aprendizagem e retenção do conhecimento, são especialmente indicadas para comparar e classificar o estado de deformação de um objeto tal como uma carroçaria de automóvel.

Neste artigo é proposta uma nova metodologia para a aplicação de um sistema neural artificial no controle e classificação do estado da carroçaria de automóvel submetida à deformação.

1. Introdução

Muitos problemas da Engenharia estão relacionados aos limites da resistência do material. Controlar a integridade do material submetido a cargas dinâmicas é tarefa complexa, porém necessária a fim de evitar-se perdas humanas e materiais. A rigor, controlar as deformações sofridas pela carroçaria de um automóvel significa, a priori, comparar seu estado atual com o original. Em uma segunda interpretação, controlar as deformações de tais peças significa monitorar suas dimensões, procedendo a medições periódicas de algumas regiões, preferencialmente estabelecidas, e comparar a progressão dos desvios.

Ao longo do tempo foram desenvolvidas várias técnicas para monitoramento das dimensões, como o controle dimensional, a espectrografia e a projeção de perfil. De qualquer maneira, em todos os casos, lida-se com o objeto real, isto é, ocorre a aplicação de algum instrumento de medição diretamente no objeto.

Ora, a aplicação de tais técnicas nem sempre são viáveis, seja pelas dimensões do objeto, seja pelas condições de aplicação e operação da peça ou

2. Avaliação da Carroçaria

Destacamos três possibilidades de se avaliar o estado da carroçaria de um automóvel:

- legal;
- técnica/econômica;
- automatizada

A Tabela 1 nos mostra como ocorre a classificação legal do grau de deformação da carroçaria de um automóvel, após colisão, e existe um ato normativo para que se decida sobre a recuperação ou a perda total do automóvel.

Na avaliação técnica/econômica um automóvel, independentemente de seu grau de deformação, poderá ser recuperado ou sucateado. Duas são as considerações básicas para a decisão:

- avaliação técnica;
- avaliação econômica.

Neste caso, o julgamento de um perito é decisivo. É um processo centrado no homem. Sendo assim, tal processo denuncia grande demanda por técnicas automatizadas, novas e eficazes. A tecnologia das RNAs

pode ser aplicada no sentido de diminuir as incertezas inerentes a tal processo.

Tabela 1: Classificação de Automóveis Acidentados

Dano/consequência	Avaliação Legal
não afeta estrutura	pequena monta
afeta estrutura	média monta
afeta estrutura	grande monta

Na Tabela 2 (ver a seguir), podemos acompanhar o resultado da avaliação conjunta.

Tabela 2: Decisão quanto à Recuperabilidade

Avaliação Técnica	Avaliação Econômica	Decisão
positiva	positiva	Recuperar
negativa	positiva	Não recuperar
positiva	negativa	Não recuperar
negativa	negativa	Não recuperar

3. Fundamentação Teórica

O desempenho final obtido por RNAs aplicado à resolução de problemas práticos é influenciado por diversos fatores [4]. Pode-se dividir esses fatores em dois grandes grupos. O primeiro diz respeito à própria RNA. Sabemos que a *topologia* das redes (tamanho, estrutura e conexões) e *algoritmo de treinamento* (taxa de aprendizado, ciclos, etc.) afetam a velocidade e eficiência do processo de aprendizado, tolerâncias a falhas e ruídos e capacidade de generalização.

O segundo diz respeito aos dados em si. Dados não previamente processados nem sempre se prestam como entrada para utilização eficiente por uma RNA [2]. Diversos tipos de dados necessitam de normalização, ou outro tratamento qualquer. Dificuldade maior representa o processamento de objetos tridimensionais por RNAs.

A Lei de Hooke aplicada a um gráfico Tensão X Deformação (*Figura 1*) afirma que, até certo limite, a tensão é proporcional à deformação ($\sigma \propto \epsilon$). A região 1, corresponde a esta proporcionalidade.

É com base nesta curva do gráfico que se estabelece o valor do desvio máximo permitido a um material, quando submetido a esforço ou choque. Toda deformação ao longo de determinado eixo apresenta uma variação mensurável. O princípio da superposição afirma que "o efeito provocado em uma estrutura por determinado carregamento combinado pode ser obtido *determinando-se separadamente os efeitos dos vários carregamentos e combinando-se os resultados obtidos*" [1]. Este princípio aplica-se sob duas condições complementares: 1) a deformação é proporcional à força; e 2) a deformação em

um eixo geométrico não afeta as condições dos outros dois eixos. Por este princípio escrevemos a deformação total como somatório das deformações calculadas sobre cada eixo do plano triortogonal, como indicado na Equação 1.

$$\epsilon_t = \epsilon_x + \epsilon_y + \epsilon_z \quad (1)$$

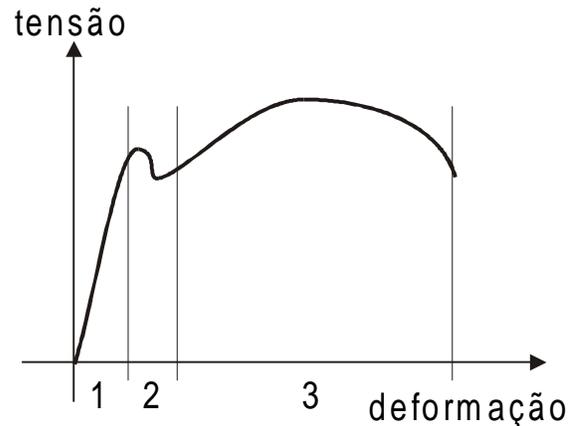


Figura 1. Gráfico Tensão X Deformação

Fatores construtivos das peças metálicas, notadamente homogeneidade e dimensões, no entanto, permitem supor para as deformações pontuais que:

- não são mensuráveis;
- estão dentro do limite elástico;
- estão na região plástica.

RNAs são especialmente indicadas para classificar o estado estrutural exatamente pela distinção possível dos períodos proporcional e plástico. Uma única rede neural artificial pode computar as deformações ocorridas em uma peça comparando os deslocamentos de uma única aresta superfície da peça

4. Linhas da Carroçaria

A coluna de um automóvel é uma peça dotada de volume e sua *seção transversal é de formato irregular*, com arestas moldadas por deformação e unidas por solda ponto. Devido à forma aerodinâmica requerida pelo veículo, as colunas possuem grande raio de curvatura, que devem ser levados em conta para sua representação matemática para fins computacionais [2].

Para avaliar um automóvel a partir do estado de sua carroçaria, precisamos distinguir três estados: a) em perfeito estado, nunca acidentado; b) deformado por acidente; c) recuperado após acidente. A Figura 2 (ver a seguir), mostra estas três possibilidades, de modo que suas linhas de contorno apresentam aspecto variável. Pode-se notar em (c) que a recuperação foi inadequada, de modo que uma RNA deve se aperceber desse fato.

Para se estudar as deformações da carroçaria de forma automatizada devemos tomar como referência um padrão possível de ser descrito por curvas matemáticas. A Figura 3 mostra tal possibilidade.

A coluna é assim combinada por duas curvas, com um ponto em comum, bem determinado. Pode-se associar a parte superior a uma linha reta de equação $Y = a_0 + a_1X$, e pode-se associar a parte inferior a uma parábola de equação $Y = a_0 + a_1X + a_2X^2$.

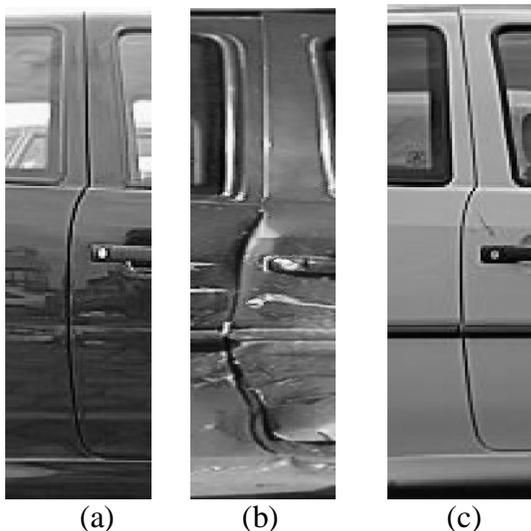


Figura 2. Exemplos de colunas: a) em perfeito estado; b) deformada por acidente; c) recuperada após acidente.

Com a aresta da parábola pode-se obter conjunto de pares (x,y) plotados em um plano bidimensional. Estabelecendo o eixo Y como referência invariante, torna-se possível construir um conjunto de padrões constituídos pelos pontos x_i do polinômio que descreve a coluna [5]. Tais padrões formarão o vetor de características de cada coluna ou aresta da carroçaria do automóvel, entrada para os sistemas neurais artificiais.

Na Figura 4, abaixo, podemos comparar os contornos da coluna do automóvel com sua descrição matemática de reta e parábola

De modo genérico, pode-se construir quaisquer curvas pela interpolação de alguns poucos pontos. Por outro lado, sistemas neurais artificiais atuam de maneira eficiente independentemente da quantidade de características. A única exigência básica é que os padrões de treinamento, quando da fase de aprendizado, sejam expressivos em termos de características.

Uma medida da qualidade do ajustamento da curva plotada aos dados apresentados, é a aderência [7], somatória dos desvios $D_1^2 + D_2^2 + D_3^2 + \dots + D_n^2$. Se esta somatória é pequena, o ajustamento é bom; se é grande, o ajustamento é mau.

O uso de RNA possibilitam a emergência de uma medida de semelhança dinâmica e contextualizada para a

aplicação em questão. Este ponto é fundamental para a real valorização das RNAs nesta aplicação.

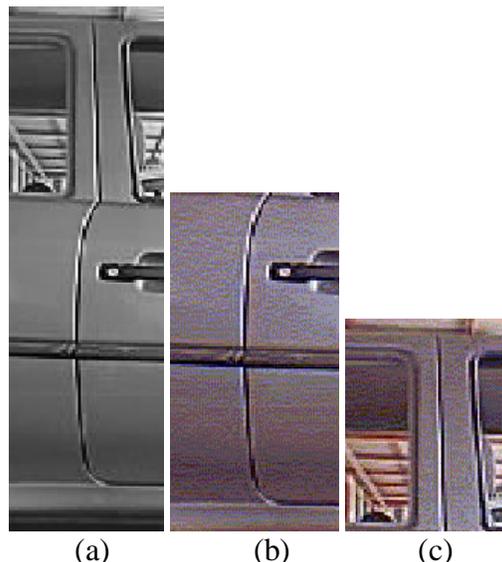


Figura 3. Uma coluna de automóvel. a) coluna inteira; b) parte inferior; c) parte superior.

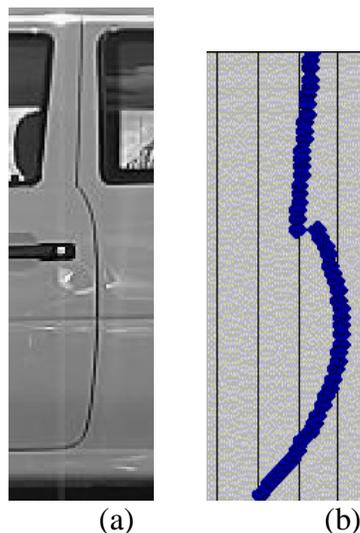


Figura 4. Contorno real X contorno matemático. a) real; b) modelagem matemática.

5. Experimentos

Uma forma de resolver problemas com a utilização de RNAs é simular vários sistemas e comparar seus desempenhos [6]. Neste trabalho, são mostradas apenas quatro redes MLP, conforme mostrado na Tabela 3 (ver a seguir). Como usual, a rede 10x2x1 tem 10 neurônios na camada de entrada (6 pontos na zona curva e 4 na zona linear), 2 neurônios escondidos e 1 neurônio de saída. O

nível de saída, pela necessidade de decidir entre duas classes apenas, tem um único neurônio.

Tabela 3: Arquiteturas testadas neste trabalho

Rede	Conexão
10x2x1 A	Total
10x2x1 B	Parcial
10x3x1 A	Total
10x3x1 B	Parcial
10x5x1 A	Total
10x5x1 B	Parcial

À primeira vista, acreditamos que, apesar de menos poderosa, a arquitetura com conexão parcial apresentasse um melhor desempenho por retratar melhor a natureza do problema (análise de linhas geométricas). Nesta conectividade restrita, as unidades intermediárias recebem estímulos apenas de seu campo incidente. A primeira unidade escondida, por exemplo, recebe estimulação apenas das quatro primeiras unidades de entrada.

As funções utilizadas para compor as RNAs foram as seguintes:

- Camada de Entrada:
Função de ativação: $\tanh(x)$
Função de saída: Clip₁₁ (ver Eq. 2)
- Camada Escondida:
Função de ativação: sigmóide
Função de saída: identidade
- Camada de saída:
Função de ativação: $\tanh(x)$
Função de saída: Clip₁₁

$$\text{Clip}_{11}(x) = \begin{cases} -1 & \text{se } x \leq -1 \\ +1 & \text{se } x \geq +1 \\ x & \text{em caso contrário.} \end{cases} \quad (2)$$

Quatro taxas de aprendizagem foram utilizadas: 0,02; 0,1; 0,2; 0,5; 0,7 e 1,0

O treinamento possibilitou uma evolução até 500, 1000, 2000 e 5000 ciclos

A base de dados utilizada foi cuidadosamente obtida através de fotografias tiradas de forma padronizada. Esta base está composta de 39 curvas (50% carros recuperáveis e 50% carros irrecuperáveis). Selecionou-se, dinamicamente, conjuntos de treinamento, teste e validação com composição aproximada de 50%, 25% e 25% respectivamente.

Nas figuras 5 a 8 (ver a seguir), cada ponto é o resultado médio de um conjunto de 10 redes MLP treinadas.

As simulações foram conduzidas em estações Sun Ultra10 com auxílio do SNNS (Stuttgart Neural Networks

Simulator), além de outros softwares auxiliares implementados pela equipe, usando a linguagem C. Estima-se que, no todo, as simulações aqui apresentadas tomaram cerca de 200 horas de computação (usando todo o tempo da estação de trabalho, isto é, sem outros usuários simultâneos).

6. Resultados

Os resultados (desempenhos na fase de teste) estão explicitados nas figuras de 5 a 10. Em todos os casos, ocorreu convergência (mesmo com a parada em um mínimo local...) do processo de treinamento. As figuras 5 e 6 mostram as situações de 500 ciclos, enquanto a 7 e a 8 foram dedicadas aos casos de 2000 ciclos. Por fim, as figuras 9 e 10 registram os resultados com 5000 ciclos de treinamento.

Através da comparação entre as figuras 5 e 6, podemos ver que, para poucos ciclos, redes totalmente conectadas apresentam resultados parecidos para uma mesma taxa de aprendizagem e que redes com maior número de neurônios na camada escondida apresentam resultados melhores com taxa de aprendizagem menor.

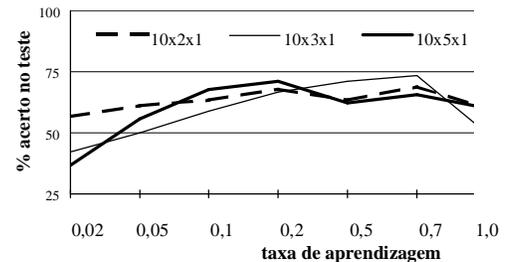


Figura 5: Arquitetura totalmente conectada até 500 ciclos.

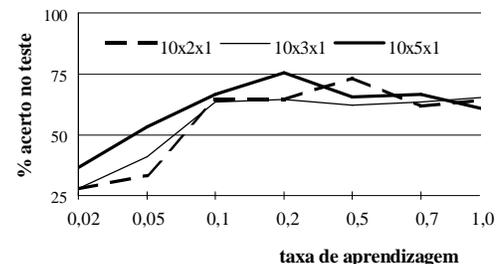


Figura 6: Arquitetura parcialmente conectada até 500 ciclos.

Como estudado, a taxa de aprendizagem livre deve ser vista como o tamanho do passo na busca pela convergência do processo de treinamento. Fica claro que passos muito pequenos, da ordem de centésimos, não possibilitam à rede perceber as regularidades estatísticas

do conjunto de treinamento. Passos muito grandes, por outro lado, também inviabilizam a retenção destas regularidades.

Perceba que a maior riqueza de estimulação apresentada pelas redes com maior conectividade resultou em melhores desempenhos (mesmo nos casos de conectividade parcial), sendo inclusive crescente conforme a taxa de aprendizagem aumentou até atingir um limite de 0,7. Como era de se esperar, a taxa de aprendizagem unitária é grande demais para a condução do treinamento.

Para a situação de 2000 ciclos, figuras 7 e 8, as redes totalmente conectadas apresentam desempenhos semelhantes para uma mesma taxa de aprendizagem.

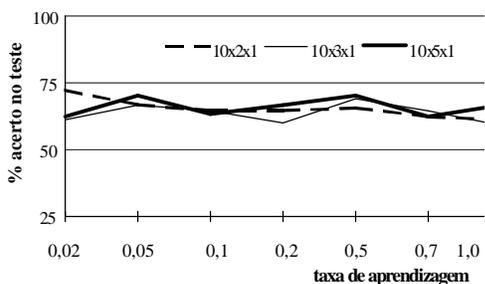


Figura 7: Arquitetura totalmente conectada – até 2000 ciclos.

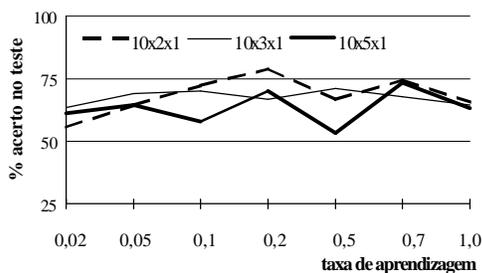


Figura 8: Arquitetura parcialmente conectada – até 2000 ciclos.

A taxa de aprendizagem acima de um certo limite acarreta perda de desempenho - no caso a taxa de aprendizagem deve ser menor que 0,5 para totalmente e 0,2 para parcialmente conectada. Isto é interessante, demonstrando que a topologia de conectividade parcial representa melhor a realidade dos dados, pois conseguiu melhor evoluir com passos pequenos dentro do espaço de possíveis soluções.

Note que redes de três neurônios na camada escondida apresentam desempenho estável e indiferente da taxa de aprendizagem, acima de 0,1 e que redes totalmente conectadas apresentam menor variação de desempenho, com o crescimento da taxa de aprendizagem

Na situação de 5000 ciclos, figuras 9 e 10, as redes parcialmente conectadas apresentam desempenhos similares independentemente da taxa de aprendizagem, enquanto as redes parcialmente conectadas com menor número de neurônios na camada escondida apresentam desempenhos melhores para as mesmas taxas de aprendizagem. Para redes totalmente conectadas, a taxa de aprendizagem acima de certo limite acarreta perda de desempenho - no caso maior que 0,2 e, para redes totalmente conectadas, taxa de aprendizagem abaixo de certo limite acarreta perda de desempenho - no caso menor que 0,2. Em redes parcialmente conectadas, a taxa de aprendizagem acima de certo limite acarreta perda de desempenho - no caso maior que 0,7.

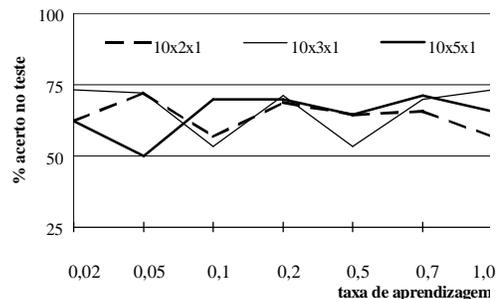


Figura 9: Arquitetura totalmente conectada – até 5000 ciclos.

Note que o aumento do número de neurônios na camada escondida acarreta perda de desempenho para redes parcialmente conectadas.

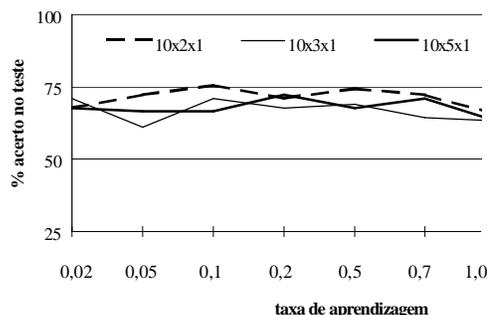


Figura 10: Arquitetura parcialmente conectada – até 5000 ciclos.

De um modo geral, observa-se que uma conectividade mais forte, traduzida pela conectividade total e pelo incremento do número de neurônios na camada escondida, enriquece a estimulação que cada neurônio recebe, possibilitando uma melhor percepção dos dados de entrada.

O modelamento proposto neste artigo vem, portanto, avaliar o uso de RNAs na determinação dos problemas de deformação mecânica. Pela literatura investigada, tal procedimento, apesar de importante, ainda não fora devidamente registrado.

7. Estudos Futuros

Os estudos futuros serão direcionados na aplicação desta metodologia no controle e monitoramento das deformações de um automóvel quando acidentado, ou submetido a solicitações não recomendadas quando em uso.

Referências

- [1] Beer, F. P., Johnston, Jr. E. R. *Resistência dos Materiais*. 3. ed. São Paulo: MAKRON Books, 1995.
- [2] Bender, E; A. *Mathematical Methods in Artificial Intelligence*. IEEE PRESS. Los Amigos – CA - USA – 1996.
- [3] Bishop, C. M., *Neural Networks for Pattern Recognition*. Oxford – UK. Oxford Press- 1995.
- [4] Braga, A. P., Carvalho, A. C. P. L. F. e Ludermir, T. B. *Fundamentos de Redes Neurais Artificiais*. Rio de Janeiro: DCC/IM, COPPE/Sistemas, NCE/UFRJ, 1998.
- [5] Giacaglia, G. *Mecânica Geral*. 10. ed. rev. Rio de Janeiro: Campus, 1982.
- [6] Spiegel, M. R. *Estatística*. McGraw-Hill do Brasil. 1974.
- [7] Xanthopulo, W., Martins, W. *Utilização de Redes Neurais Artificiais na Classificação das Deformações das Colunas Centrais de Automóveis Acidentados - Relatório Interno 001/LSI/EEE-UFG, Out/98*.
- [8] Xanthopulo, W., Martins, W. *Modelos Matemáticos Aplicados à Computação na Representação das Colunas de Automóveis - Relatório Interno 004/LSI/EEE-UFG, Dez/98*.