

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA QUÍMICA
DESENVOLVIMENTO DE PROCESSOS QUÍMICOS

Aplicação de Redes Neurais no Processo de *Filament Winding*

Sheila Contant

Autora

Liliane Maria Ferrareso Lona

Orientadora

Verônica Maria de Araújo Calado

Co-Orientadora


Dissertação de Mestrado apresentada à

**Faculdade de Engenharia Química como parte dos requisitos
exigidos para a obtenção do título de Mestre em Engenharia Química.**

Campinas - São Paulo

Dezembro/2002

UNICAMP
BIBLIOTECA CENTRAL



UNIDADE	80
Nº CHAMADA	T/UNICAMP
	C767a
V	EX
TOMBO BC/	52372
PROC.	124/08
C	<input type="checkbox"/>
D	<input checked="" type="checkbox"/>
PREÇO	R\$ 11,00
DATA	
Nº CPD	

CM00179788-1

318 1D 279888

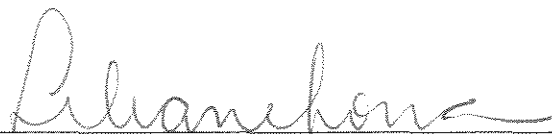
FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

C767a Contant, Sheila
Aplicação de redes neurais no processo de filament winding / Sheila Contant.--Campinas, SP: [s.n.], 2002.

Orientadora: Liliane Maria Ferrareso Lona.
Co-orientadora: Verônica Maria de Araújo Calado.
Dissertação (mestrado) - Universidade Estadual de Campinas, Faculdade de Engenharia Química.

1. Redes neurais (Computação). 2. Simulação (Computadores). 3. Compósitos poliméricos. 4. Plástico reforçado. I. Lona, Liliane Maria Ferrareso. II. Calado, Verônica Maria de Araújo. III. Universidade Estadual de Campinas. Faculdade de Engenharia Química. III. Título.

Dissertação de Mestrado defendida por Sheila Contant e aprovada em 17 de Dezembro de 2002 pela banca examinadora constituída pelos doutores:



Profa. Dra. Liliane Maria Ferrareso Lona - Orientadora



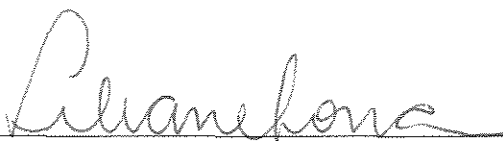

Profa. Dra. Ana Rita Morales



Prof. Dr. Roberto de Campos Giordano

200306045

Este exemplar corresponde à versão final da Dissertação de Mestrado em Engenharia
Química.

A handwritten signature in black ink, appearing to read 'Liliane Lona', is written over a horizontal line.

Profª. Dra. Liliane Maria Ferrareso Lona - Orientadora

Dedico este trabalho a meus queridos pais Leonilda e José
e a minha querida irmã Cilene.

AGRADECIMENTOS

À Profª. Dra. Liliane Maria Ferrareso Lona pela excelente orientação, pelo grande incentivo e profissionalismo com o qual conduziu a orientação deste trabalho.

À Profª. Dra. Verônica Maria de Araújo Calado, pela excelente co-orientação e contínua motivação para o desenvolvimento deste trabalho.

Ao Prof. Dr. Rubens Maciel Filho, pelo incentivo e pela disponibilidade.

Aos colegas do laboratório LASSPQ, em especial ao Fabiano Fernandes, pelo apoio e pela amizade.

A FAPESP, pelo financiamento do projeto (proc. 00/10090-7).

À empresa Polyplaster, pelo fornecimento dos dados de processo.

A minha família e a todos que contribuíram para o desenvolvimento deste trabalho.

RESUMO

Compósitos poliméricos ou plásticos reforçados são materiais formados a partir de uma matriz polimérica e um reforço. Atualmente, o setor dos compósitos poliméricos é um dos mais promissores, devido às muitas vantagens desses materiais, entre elas redução do peso, resistência à corrosão e a temperaturas elevadas, e redução dos custos de fabricação quando comparados aos materiais convencionais da engenharia. O Brasil é o líder desse mercado na América Sul, região que tem exibido o maior crescimento mundial desde 1993.

Entre os diversos métodos de fabricação de compósitos poliméricos de matriz termorrígida (que representa cerca de 3/4 dos compósitos poliméricos) e reforço de fibras contínuas, está o *filament winding*, muito empregado na produção de sólidos de revolução, como dutos, cilindros e tanques. Uma das grandes restrições para uma maior exploração comercial dos métodos de preparação de compósitos, incluindo o *filament winding* (filamento contínuo), reside na dificuldade de relacionar os vários parâmetros do sistema com a qualidade do produto final e com a eficiência do processo.

Neste trabalho, redes neurais artificiais foram aplicadas no processo de *filament winding* em dois casos: (a) predição de propriedades que descrevem a qualidade do produto final (propriedades mecânicas e térmicas de peças) utilizando como conjunto de treinamento ensaios industriais de caracterização experimental e (b) predições do comportamento térmico de compósitos durante a etapa de cura, sendo que para o treinamento dessas redes foram obtidos dados através do modelo Lee-Springer. Foram desenvolvidos programas computacionais empregando os algoritmos de *backpropagation* e delta-barrá-delta, e a influência de cada variável de entrada nas saídas da rede foi determinada através da Equação de Garson. Os resultados encontrados mostraram a eficiência da aprendizagem das redes em todos os casos estudados. A aplicação de redes neurais na modelagem do processo de *filament winding* pode levar a uma melhor compreensão do processo, redução do tempo de desenvolvimento de novos produtos e do custo.

Palavras-chave: redes neurais, simulação, compósitos poliméricos, *filament winding*.

ABSTRACT

Polymer composites or reinforced plastics are materials made with a polymer matrix and a reinforcement. Nowadays polymer composite market is one of the most promising, because of the many advantages of these materials such as weight saving, corrosion and temperature resistance and manufacturing cost reduction, when compared to conventional engineering materials. Brazil is the leader of polymer composite market in South America, which has shown the largest growth of this segment in the world since 1993.

Among manufacturing methods for thermoset polymer matrix composites (that represent about 3/4 of the polymer composites) and continuous fiber reinforcement is the filament winding, often used for manufacture of closed-surface structures such as pipes, cylinders and tanks. One of the constraints in the great commercial exploitation of the composite manufacturing methods, including filament winding, is the difficulty to relate the many process parameters with product quality and process efficiency.

In this work, artificial neural networks were applied in the filament winding process in two cases: (a) prediction of properties that describe final product quality (mechanical and thermal strength of parts) using as training set industrial tests of experimental characterization and (b) prediction of thermal behavior of composites during cure step, being the networks trained with data obtained using Lee-Springer model. Computer programs have been developed with backpropagation and delta-bar-delta algorithms and the influence of each input variable in the network outputs has been determined using Garson Equation. Results obtained have shown network learning efficacy in all studied cases.

Application of neural networks in the filament winding process can give a better understanding of the process, reducing product development time and cost.

NOMENCLATURA

Letras Latinas

A = fator pré-exponencial

α_x = coeficiente de dilatação térmica na direção circunferencial

α_y = coeficiente de dilatação térmica na direção axial

C = calor específico

DN = diâmetro nominal

E = erro da rede neural

E_a = energia de ativação

E_x = módulo de elasticidade na tração circunferencial

E_y = módulo de elasticidade na tração axial

h = espessura

I = porcentagem de influência

k = parâmetro do algoritmo delta-barra-delta

$k^*(T)$ = constante da taxa

K_{c22} = condutividade térmica transversa da camada de compósito

K_{f22} = condutividade térmica transversa da fibra

K = condutividade térmica da resina

m = conjunto de treinamento

\underline{m} = parâmetro do modelo cinético de cura autocatalítico

n = iteração da rede neural

\underline{n} = parâmetro do modelo cinético de cura de ordem \underline{n}

M_{tubo} = peso do tubo da Polyplaster

M = total de exemplos de treinamento apresentados à rede

N_{hid} = número de neurônios na camada *hidden*

N_{out} = número de neurônios na camada *output*

O_j = saída da do neurônio j da camada *hidden*

OL_k = saída do neurônio k da camada *output* (saída gerada pela rede neural)

R = constante dos gases

R^2 = coeficiente de determinação

S = módulo de cisalhamento (no plano)

S_j = somatório realizado pelo neurônio j da camada *hidden*

SL_k = somatório realizado pelo neurônio k da camada *output*

U_x = maior razão de Poisson

v = fração em volume

t = tempo

T = temperatura

W_{ij} = peso da conexão que liga os neurônios i (camada *input*) e j (camada *hidden*)

WL_{jk} = peso da conexão que liga os neurônios j (camada *hidden*) e k (camada *output*)

X = tensão de tração circunferencial

X = entrada da rede neural

X_{escal} = *input* escalonado

Y' = tensão de compressão axial

Y = tensão de tração axial

Y = saída desejada da rede neural

Y_{escal} = *output* escalonado

Y_k^m = saída desejada para o neurônio k da camada *output*, para o conjunto de treinamento m

Letras Gregas

β = parâmetro do algoritmo delta-barra-delta

ξ = parâmetro do algoritmo delta-barra-delta

δ = fator de correção do erro da rede neural

η = taxa de aprendizagem da rede neural

ψ = termo de momento da rede neural

α = grau de cura

ρ = densidade

θ = *bias*

μ = viscosidade

Subscritos

c = compósito

$cure$ = material curado

f = fibra

i = neurônio *input*

j = neurônio oculto

k = neurônio da camada *output*

m = mandril

r = resina

$uncure$ = material não curado

SUMÁRIO

CAPÍTULO 1: INTRODUÇÃO	21
CAPÍTULO 2: REDES NEURAIIS	25
2.1: Rede <i>Multilayer Perceptron</i> e <i>Backpropagation</i>	29
2.2: Resumo do Treinamento da Rede	35
2.3: Seleção do Conjunto de Treinamento	36
2.4: Pré-Processamento dos Dados	36
2.5: Delta-Barra-Delta	38
CAPÍTULO 3: COMPÓSITOS POLIMÉRICOS	41
3.1: Classificação dos Materiais Compósitos	42
3.2: Matrizes Poliméricas	45
3.3: Fibras	48
3.4: Aspectos Econômicos	49
3.5: Métodos de Fabricação	51
3.5.1: <i>Hand Lay-up</i>	53
3.5.2: <i>Spray-up</i>	54
3.5.3: Pultrusão	55
3.5.4: SMC	57
3.5.5: <i>Filament Winding</i>	59
CAPÍTULO 4: MODELAGEM DO PROCESSO DE <i>FILAMENT WINDING</i>	63
4.1: Modelo Lee-Springer	65
4.1.1: Submodelo Termoquímico	66
CAPÍTULO 5: DADOS UTILIZADOS NO TREINAMENTO DAS REDES	71
5.1: Caso (a) - Dados da Empresa Polyplaster	71
5.2: Caso (b) - Dados do Modelo Lee-Springer	77

CAPÍTULO 6: METODOLOGIA PARA TREINAMENTO DAS REDES	83
6.1: Caso (a) - Predição de Propriedades Finais	83
6.2: Caso (b) - Predição de Temperatura	86
6.3: Desenvolvimento do Programa Computacional	88
CAPÍTULO 7: RESULTADOS E DISCUSSÃO	93
7.1: Caso (a) - Predição de Propriedades Finais	93
7.1.1: Análise dos Pesos	101
7.1.2: Avaliação da Influência das Variáveis de Entrada	102
7.1.3: Otimização do Processo	104
7.2: Caso (b) - Predição de Temperatura	106
7.2.1: Avaliação da Influência das Variáveis de Entrada	111
CAPÍTULO 8: CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS	113
BIBLIOGRAFIA	117

CAPÍTULO 1: INTRODUÇÃO

Atualmente, o emprego dos compósitos poliméricos é tão extenso (segundo a Revista do Plástico Reforçado, 2000, estão catalogadas em todo mundo mais de 40 mil possibilidades de utilização) que é difícil apontar um setor que não se utilize desse tipo de material. Entre as principais áreas estão: transporte, construção civil, indústria química, mobiliária, indústria do lazer, de eletrodomésticos, aeronáutica, naval, eletroeletrônica e bélica. Na indústria química, algumas das utilizações são tubos, dutos, tanques, reservatórios, grades de piso e revestimento anticorrosivo.

O mercado de compósitos poliméricos é um dos mais promissores em todo mundo. Mesmo representando apenas 3% do mercado global, o crescimento anual do setor na América do Sul, desde 93, foi o maior de todo o mundo (14,5%), demonstrando o imenso espaço que os materiais compósitos possuem nessa região. O Brasil, como líder desse mercado, será o principal responsável por essa ampliação (Revista do Plástico Reforçado, 2000).

Entre as vantagens desse tipo de material estão: baixo peso (o que reduz os custos de montagem e facilita a instalação), resistência à corrosão e a elevadas temperaturas, propriedades mecânicas adequadas às solicitações do produto final, e fabricação de peças com redução no número de partes, permitindo economia com elementos de ligação, tempo e mão-de-obra.

Estima-se que mais que 3/4 dos compósitos poliméricos são fabricados com matriz termorrígida (MATTHEWS e RAWLINGS, 1996). Entre os métodos de fabricação de compósitos poliméricos de matriz termorrígida está o *filament winding* (filamento contínuo ou enrolamento filamentar), bastante empregado na fabricação de peças como dutos e tanques por apresentar baixo custo, permitir alta produção e peças com uniformidade de propriedades.

A literatura mostra vários trabalhos que tratam da modelagem do método *filament winding*, os quais envolvem modelos analíticos complexos e longas rotinas experimentais, uma vez que as interações entre as muitas variáveis do processo não são facilmente determinadas.

Neste trabalho, propõe-se o estudo do processo de *filament winding* através de redes neurais, uma técnica que nos últimos anos tem atraído a atenção de profissionais de diversas áreas, principalmente das engenharias e ciências exatas, sendo considerada, conforme citado em BAUGHMAN e LIU (1995), uma das melhores ferramentas computacionais já desenvolvidas, devido a sua capacidade para imitar a habilidade do cérebro humano para aprender através de exemplos e manipular sistemas altamente complexos.

As redes neurais começaram a ser estudadas na década de 40, mas somente no final da década de 80 essa técnica de inteligência artificial começou a ganhar amplo destaque. O primeiro artigo na área química, por exemplo, foi publicado em 1988 pelo prof. David M. HIMMELBLAU da Universidade do Texas e seu aluno, Josiah C. HOSKINS, que estudaram o diagnóstico de falhas em um reator químico. Desde então, o número de publicações que tratam da sua utilização na análise dos mais diversos tipos de problemas cresceu significativamente. CHTIOUI *et alii* (1999), por exemplo, determinaram através de redes neurais o teor de umidade em folhas (que está associada ao desenvolvimento de fungos patogênicos) a partir de fatores como temperatura e velocidade do vento. VERT *et alii* (2000) demonstraram a possibilidade de construção de um modelo de redes neurais para a definição da atividade antibacterial de substâncias diretamente a partir de suas estruturas. MELVIN *et alii* (2000) estudaram a utilização de redes neurais para predição da ocorrência de rejeição nos estágios iniciais do pós-operatório de transplante de fígado.

A rede neural pode ser treinada para aprender a relação existente entre conjuntos de variáveis e posteriormente pode ser usada para fazer predições a partir de novos e diferentes *inputs*. No entanto, a rede não se mostra suficientemente confiável quando trabalha com dados que estejam fora do espaço do conjunto *input-output* de aprendizado.

De modo geral, a aplicação de redes neurais tem se mostrado muito atrativa por apresentar as seguintes características (ELGIBALY e ELKAMEL, 1998):

- Dispensa o conhecimento de fórmulas específicas que representem o processo em estudo, isto é, para se trabalhar com redes neurais é necessário apenas decidir quais são os *inputs* e, dependendo do problema, *outputs* importantes para o sistema.
 - Pode fornecer resultados com elevada precisão.
-

- É flexível, isto é, capaz de se adaptar a novos conjuntos *input-output*.
- Depois de treinar a rede, realizar previsões é uma tarefa simples.

Essa ferramenta computacional também é bastante interessante do ponto de vista econômico, uma vez que é capaz de realizar previsões, dispensando medições experimentais ou de campo.

Neste trabalho, redes neurais artificiais foram aplicadas no processo de *filament winding* em dois casos: (a) previsão de propriedades mecânicas e térmicas do produto final e (b) previsão de temperatura no interior das peças durante a etapa de cura.

Para o treinamento da rede no caso (a), foram utilizados dados de processo de uma planta industrial, sendo que as entradas da rede foram constituídas por composições e dimensões da peça. Os dados foram fornecidos pela Polyplaster, uma empresa localizada em Betim, Minas Gerais. A Polyplaster foi fundada em 1969 e trabalha com a produção de peças de materiais compósitos constituídos principalmente por resina éster vinílico, poliéster e fibra de vidro. Entre os principais produtos fabricados por essa empresa estão: tubos e conexões (40%), estações de tratamento de água (30%) e tanques para produtos químicos e reservatórios de água (20%). Para tanto, a Polyplaster utiliza, além da técnica de *filament winding*, também *hand lay-up* e *spray-up*.

Para o treinamento da rede no caso (b), foram utilizados dados gerados pelo *software* Windthick da Universidade de Stanford, o qual é baseado no modelo Lee-Springer (LEE e SPRINGER, 1990a) para modelagem do processo de *filament winding* para fabricação de cilindros de matriz termorrígida. Como *inputs* para essa rede, foram consideradas condições operacionais, características geométricas da peça e propriedades da resina e fibra.

Conforme apontado em MEERT e RIJCKAERT (1998) e também em GUIMARÃES e MCGREAVY (1995), uma das mais promissoras ferramentas computacionais para aplicação na indústria de processos químicos é a rede neural, uma vez que esta é capaz de trabalhar com processos altamente complexos e não lineares, típicos dessa área. A aplicação das redes neurais na modelagem de plantas industriais de larga escala tem sido descrita na literatura, por exemplo, na modelagem de plantas de tratamento

de efluentes e refinaria de petróleo (BOGER, 1997, LONA BATISTA, 1996) e tende a crescer, uma vez que as fortes pressões econômicas e ecológicas exigem cada vez mais uma operação eficiente dessas plantas.

Com relação ao processo de *filament winding*, a aplicação de redes neurais pode levar a uma melhor compreensão do processo, aumento na eficiência produtiva, e redução do tempo de desenvolvimento de produtos e dos custos.

CAPÍTULO 2: REDES NEURAIS

A Tabela 1 resume as principais contribuições das pesquisas em redes neurais, que teve seu início com o primeiro modelo matemático descrevendo um neurônio, desenvolvido por McCulloch e Pitts, pesquisadores da universidade de Chicago, em 1943. Os primeiros anos após a publicação desse trabalho pioneiro foram de grande atividade, mas, a esse período, seguiu-se um outro de estagnação nas pesquisas, o que se deveu, dentre outros fatos, à publicação, em 1969, do livro *Perceptrons* de Minsky e Papert, que demonstraram matematicamente a existência de limites fundamentais nas tarefas realizadas por um *perceptron* de uma camada, e afirmaram sem provas que uma estrutura multicamadas não conseguiria superar essas limitações. Conforme citado em HAYKIN (2001), a partir da década de 80, o interesse pelas redes neurais ressurgiu, principalmente devido aos trabalhos de Hopfield (1982) e Rumelhart e McClelland (1986) e também devido à existência de computadores mais poderosos e acessíveis. Uma excelente revisão histórica sobre as redes neurais também pode ser encontrada em VON ZUBEN (1993).

Tabela 1: Histórico das Pesquisas em Redes Neurais (VON ZUBEN, 1993).

Ano	Pesquisador	Contribuição
1943	McCulloch e Pitts	Neurônio artificial
1948	Wiener	Cibernética
1949	Hebb	Aprendizado de Hebb
1957	Rosenblatt	Regras de ajuste dos pesos
1958	Widrow e Hoff	Regras de ajuste dos pesos
1969	Minsky e Papert	<i>Perceptron</i>
1960-1980	Kohonen, Grossberg, Widrow, Anderson, Caianiello, Fukushima	Diversas
1974	Werbos	Tese de doutorado com o <i>backpropagation</i>
1982	Hopfield, Kohonen	Redes de Hopfield e Kohonen
1986	Rumelhart e McClelland	Algoritmo de <i>backpropagation</i>

A rede neural artificial (RNA ou ANN, do *inglês artificial neural network*), também denominada rede neuronal, neurocomputador, rede connexionista, processador paralelo distribuído, ou ainda rede neural computacional (CNN, do *inglês computational neural network*, SUMPTER e NOID, 1996), pode ser definida como um processador massivamente paralelo constituído de unidades simples de processamento que possuem uma propensão natural para armazenar conhecimento experimental e disponibilizá-lo para uso (HAYKIN, 2001).

A literatura mostra diversos trabalhos recentes que comprovam a eficiência das redes neurais no estudo de problemas da área de materiais, incluindo os materiais compósitos. Exemplos são a predição de propriedades de compósitos de concreto (KONDERLA e MOKANEK, 2000), a predição do comportamento mecânico de compósitos poliméricos de fibra de carbono e fibra de vidro (LEE *et alii*, 1999) e a modelagem de um processo de fabricação de compósitos de matriz termoplástica (SPOERRE e KENDALL, 1998). Uma revisão sobre aplicações das redes neurais em problemas envolvendo caracterização e análise de materiais pode ser encontrada em SUMPTER e NOID (1996).

A rede neural pode ser implementada usando componentes eletrônicos ou pode ser simulada em um *software* em um computador digital convencional (essa é a forma abordada neste trabalho), e se assemelha ao cérebro humano em dois aspectos principais (HAYKIN, 2001):

- O conhecimento do ambiente é adquirido pela rede através de um processo de aprendizagem.
- Conexões inter-neurônios que possuem uma certa força, conhecidas como pesos sinápticos, são usadas para armazenar o conhecimento adquirido.

A aprendizagem, no contexto das redes neurais, pode ser definida como um processo através do qual os parâmetros livres da rede são adaptados por meio de um processo contínuo de estímulos do ambiente. Em outras palavras, o objetivo do aprendizado

em redes neurais é a obtenção de um modelo implícito do sistema em estudo, por meio do ajuste dos parâmetros da rede.

Conforme ilustra a Figura 1 a seguir, o processo de aprendizagem é caracterizado pelo paradigma e algoritmo de aprendizagem. Algoritmo de aprendizagem é um conjunto de regras bem definidas para a solução do problema de aprendizagem (basicamente, os algoritmos diferem entre si na maneira através da qual o ajuste dos pesos é formulado) enquanto que paradigma de aprendizagem se refere a um modelo do ambiente no qual a rede neural opera.

O aprendizado supervisionado ou aprendizado associativo faz uso de exemplos de estímulo-resposta no processamento interno visando minimizar a diferença entre a saída gerada pela rede e a saída desejada. Um elemento essencial desse paradigma de aprendizagem é a presença de um "professor" externo cujo papel é providenciar o conhecimento do ambiente, isto é, conjuntos de exemplos *input/output* que representem o comportamento que deve ser apresentado pela rede neural. Os *inputs* são apresentados a rede, a qual processa os dados para produzir saídas que são comparadas com os resultados conhecidos. O erro determinado por essa comparação é usado para ajustar os pesos.

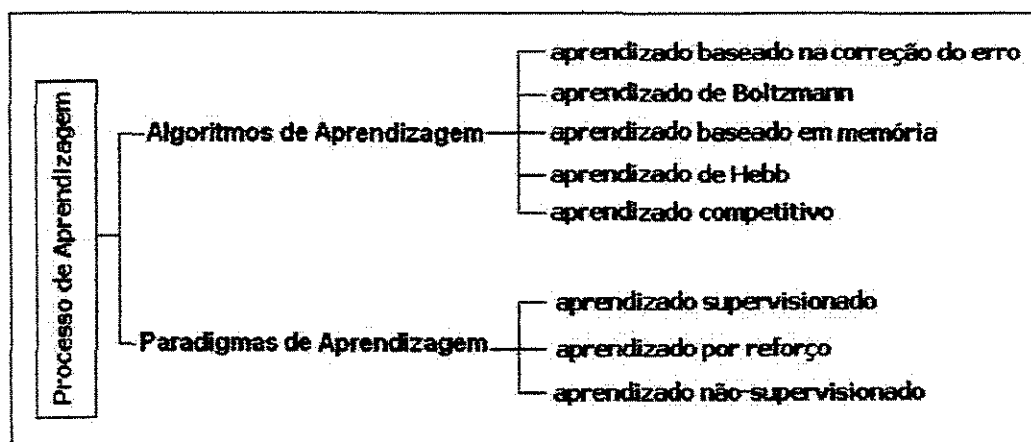


Figura 1: Processo de Aprendizagem da Rede Neural (HAYKIN, 1994).

A forma de aprendizagem supervisionada descrita anteriormente é uma aprendizagem por correção de erro. Como uma medida de desempenho do sistema, pode-se utilizar, por exemplo, o erro médio quadrático.

Entre os algoritmos que possibilitam a resolução de problemas de aprendizado supervisionado, o algoritmo de *backpropagation* ou retropropagação tem sido o mais amplamente utilizado, por sua facilidade de implementação e comprovada história de sucessos, entre outras características (esse algoritmo será descrito na sequência).

De modo geral, o algoritmo de *backpropagation* consiste de duas fases distintas: *forward* e *backward*. Na fase *forward*, os sinais *input* se propagam através da rede, camada a camada, e valores de saída são gerados. Esses valores de saída são comparados com os valores esperados e, em uma segunda fase (fase *backward*), os pesos nas conexões são modificados de acordo com a diferença entre o valor esperado e o calculado pela rede neural, de modo a minimizar o erro.

No aprendizado não-supervisionado, também denominado auto-organizado ou autônomo, ao contrário do aprendizado supervisionado, não há um "professor" externo para supervisionar o processo de aprendizagem, como ilustra a Figura 2. Nesse paradigma, o aprendizado é baseado apenas nos estímulos recebidos pela rede neural. Basicamente, a rede deve aprender a categorizar os estímulos. Para fazer isso, o algoritmo dispõe de um conjunto de regras de natureza local, isto é, a modificação aplicada ao peso de um neurônio é confinada à vizinhança imediata daquele neurônio.

A Figura 2 a seguir ilustra alguns dos conceitos envolvidos nos paradigmas de aprendizagem.

No aprendizado por reforço, que encontra aplicações por exemplo na robótica, o comportamento da rede é avaliado apenas com base em algum critério numérico, fornecido em instantes espaçados de tempo. Neste trabalho, o paradigma supervisionado será usado. Explicações mais detalhadas para os demais paradigmas (que não são o escopo deste trabalho) poderão ser encontradas em HAYKIN (1994) e também em SUMPTER e NOID (1996).

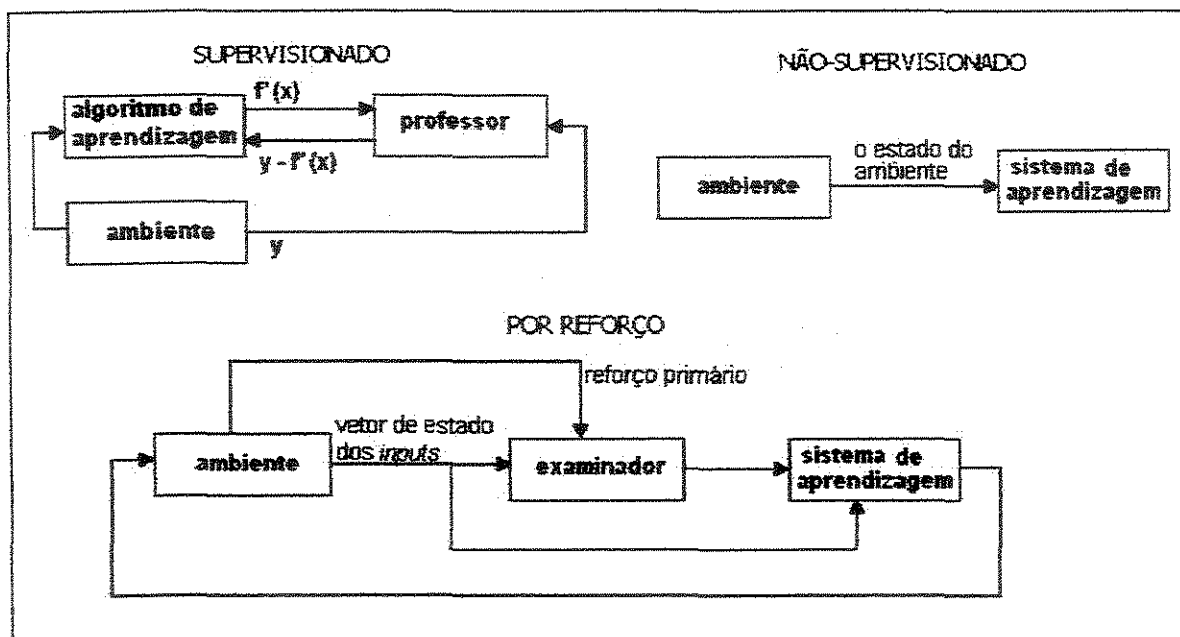


Figura 2: Conceitos Gerais Envolvidos nos Três Tipos de Paradigmas de Aprendizagem mais Comumente Usados nas Redes Neurais (SUMPTER e NOID, 1996).

2.1: Rede *Multilayer Perceptron* e *Backpropagation*

A Figura 3 a seguir ilustra uma rede neural tipo *Multilayer Perceptron* (MLP), a qual é formada por vários elementos que processam informações, denominados neurônios (representados pelos círculos), distribuídos em três tipos distintos de camadas: camada de entrada ou camada *input* (recebe as informações referentes aos dados de entrada), camada oculta ou camada *hidden* (pode ser mais do que uma; processa as informações e gera as entradas da próxima camada) e camada de saída ou camada *output* (fornece os resultados de saída da rede). A cada conexão que liga os neurônios é atribuído um número real, chamado peso. O treinamento (ou fase de aprendizado) da rede consiste basicamente em um ajuste desses pesos.

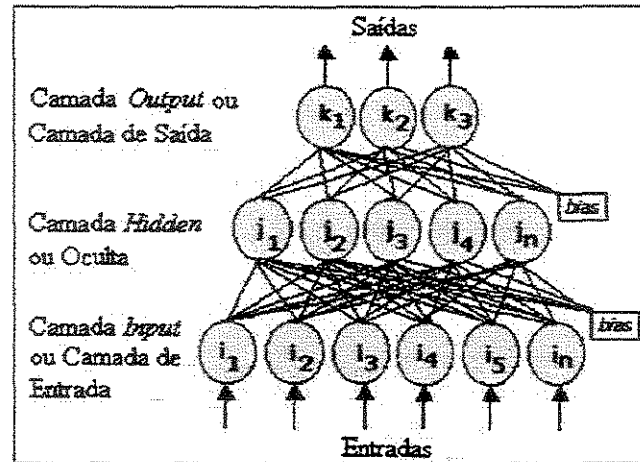


Figura 3: Rede Neural *MLP*.

Conforme mencionado anteriormente, o algoritmo mais utilizado nos problemas de aprendizado supervisionado é o de *backpropagation*. Esse tipo de algoritmo é bastante adequado para redes do tipo *feedforward*, que são aquelas nas quais a informação segue uma única direção.

O tipo de processamento realizado por um neurônio é mostrado na Figura 4, que ilustra o neurônio j da camada *hidden*. Esse neurônio recebe as informações dos neurônios da camada *input* e gera uma saída, a qual vai ser uma das entradas da camada *output*, como descrevem as Equações 1 e 2 a seguir.

$$S_j = \sum_{i=1}^{N_{hid}} W_{ij} X_i + \theta_j \quad (1)$$

$$O_j = f(S_j) \quad (2)$$

Sendo: S_j = somatório realizado pelo neurônio j da camada *hidden*

O_j = saída do neurônio j da camada *hidden*

W_{ij} = peso da conexão que liga os neurônios i (camada *input*) e j (camada *hidden*)

X_i = entrada da rede, correspondente ao neurônio i

N_{hid} = número de neurônios na camada *hidden*

θ_j = *bias* (peso especial correspondente a uma entrada de valor 1)

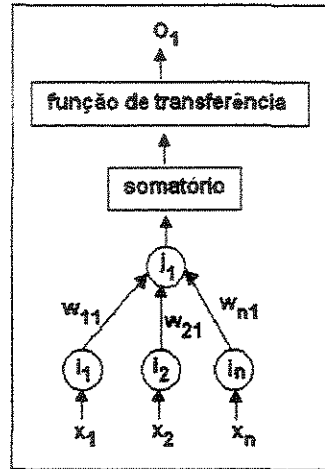


Figura 4: Processamento Realizado por um Neurônio Oculto.

A Equação 2 mostra que a saída do neurônio é uma função dos *inputs* e dos pesos. Essa função, $f(S_j)$, é chamada função de transferência, função de ativação ou função restritiva, já que restringe o intervalo permissível de amplitude do sinal de saída a um valor finito. Como será mostrado adiante, a função de transferência deve possuir uma derivada contínua e fácil de ser calculada.

Uma das mais eficientes funções de transferência utilizada na construção de redes neurais, e que será adotada neste trabalho, é a função sigmoideal ou função logística, mostrada na Equação 3. A função sigmoideal, que é um exemplo de função sigmóide (o gráfico tem a forma de "s"), introduz uma não-linearidade suave e sua utilização tem uma motivação biológica, pois procura levar em conta aspectos relacionados a neurônios reais (HAYKIN, 2001).

$$f(S_j) = \frac{1}{1 + e^{-S_j}} \quad (3)$$

A partir dos valores das saídas da camada oculta (O_j), os neurônios da camada *output* calculam, de maneira análoga, as saídas da rede, como mostram as Equações 4 e 5.

$$SL_k = \sum_{j=1}^{Nout} WL_{jk} O_j + \theta_k \quad (4)$$

$$OL_k = f(S_k) = \frac{1}{1 + e^{-S_k}} \quad (5)$$

Sendo: SL_k = somatório realizado pelo neurônio k da camada *output*

OL_k = saída do neurônio k da camada *output* (que é a saída da rede neural)

WL_{jk} = peso da conexão que liga os neurônios j (camada *hidden*) e k (camada *output*)

$Nout$ = número de neurônios na camada *output*

Após o cálculo da saída da rede (OL), esse valor é comparado com o *output* real (Y) e, baseado no erro encontrado, os pesos sofrem modificações até que a rede consiga aprender a relação existente entre os conjuntos de dados.

Uma vez que os desvios entre os valores reais e os preditos pela rede podem assumir tanto valores negativos quanto positivos, o erro de treinamento a ser minimizado, mostrado na Equação 6, é o quadrado da diferença (VON ZUBEN, 1993).

$$E = \frac{1}{2M} \sum_{k=1}^{Nout} \sum_{m=1}^M (OL_k^m - Y_k^m)^2 \quad (6)$$

Sendo: E = erro de treinamento

M = total de exemplos de treinamento apresentados à rede

Y_k^m = saída esperada para o neurônio k da camada *output*, para o conjunto de treinamento m

Os novos pesos, W e θ , para um dado conjunto de treinamento m , podem ser calculados através das Equações 7 e 8.

$$W^m = W^{(m-1)} + \Delta W^m \quad (7)$$

$$\theta^m = \theta^{(m-1)} + \Delta \theta^m \quad (8)$$

Para obtenção das correções dos pesos e *bias* das equações acima, utiliza-se a variação do erro com relação aos pesos e *bias*, como mostram as Equações 9 e 10. Após simplificações, as variações dos pesos, ΔW e $\Delta \theta$, podem ser obtidas pelas Equações 11 e 12, onde η e ψ são constantes positivas chamadas taxa de aprendizagem e termo de momento, respectivamente. O parâmetro δ_j representa um fator de correção do erro (SAVKOVIC-STEVANOVIC, 1994).

$$\Delta W_{ij} = -\frac{\partial E}{\partial w_{ij}} \eta \quad (9)$$

$$\Delta \theta_j = -\frac{\partial E}{\partial \theta_j} \eta \quad (10)$$

$$\Delta W_{ij}^m = \eta \delta_j^m O_j^m + \psi \Delta W_{ij}^{(m-1)} \quad (11)$$

$$\Delta \theta_j^m = \eta \sum_m \delta_j^m \quad (12)$$

As correções dos pesos que ligam as camadas *input-hidden* e *hidden-output* utilizam expressões diferentes de δ_j , mostradas a seguir.

(a) Camada *Output*

$$\delta_j = (Y_k - OL_k) \cdot f'(S_j) \quad (13)$$

Uma vez que o processo de aprendizagem é iterativo, será necessário calcular muitas vezes a derivada da função de transferência (f'), e por isso, essa função deve apresentar uma derivada contínua e fácil de ser calculada.

Considerando uma função de transferência sigmoidal (Equação 3), tem-se:

$$\delta_j = (Y_k - OL_k) OL_k (1 - OL_k) \quad (14)$$

(b) Camada *Hidden*

$$\delta_j = f'(S_j) \sum_k \delta_j W_{jk} \quad (15)$$

Da mesma forma, para uma função de transferência signoidal, tem-se:

$$\delta_j = O_j (1 - O_j) \sum_k \delta_j W_{jk} \quad (16)$$

Uma característica bastante interessante das redes neurais é que, a partir dos valores dos pesos obtidos durante a fase de treinamento, é possível avaliar a influência das variáveis de entrada nas saídas do sistema, através da Equação 17 desenvolvida por GARSON (1991). Além de permitir uma análise de como as variáveis afetam o processo estudado, essa equação pode possibilitar, dependendo dos resultados encontrados, a exclusão de neurônios da camada de entrada, o que permite simplificar a rede neural e pode melhorar a sua performance.

$$I = \frac{\sum_{i=1}^{N_{hid}} \left[\left(|W_j| / \sum_{k=1}^{N_{inp}} W_{j,k} \right) \times |WL_j| \right]}{\sum_{i=1}^{N_{inp}} \left\{ \sum_{j=1}^{N_{hid}} \left[\left(|W_{i,j}| / \sum_{k=1}^{N_{inp}} W_{i,j,k} \right) \times |WL_j| \right] \right\}} \times 100 \quad (17)$$

Sendo: I = porcentagem de influência

$|W_j|$ = valor em módulo do peso (*input-hidden*)

$|WL_j|$ = valor em módulo do peso (*hidden-output*)

Além da fase de treinamento, uma etapa bastante importante do trabalho com as redes neurais é a fase de teste ou generalização. Essa etapa é realizada simultaneamente com a etapa de treinamento e consiste na aplicação dos pesos obtidos naquela etapa em um novo conjunto de dados. A generalização é influenciada por três fatores: (i) tamanho do conjunto de treinamento e o quão representativo do ambiente de interesse ele é, (ii) arquitetura da rede neural e (iii) complexidade física do problema em questão. Uma boa generalização exige uma grande quantidade de exemplos de treinamento, mas infelizmente o tamanho ideal desse conjunto ainda é uma área de pesquisa em aberto (HAYKIN, 2001).

2.2: Resumo do Treinamento da Rede

- (a) Calcule a saída da camada *hidden* (Equação 2)
- (b) Calcule a saída da camada *output* (Equação 5)
- (b) Calcule a diferença entre o valor esperado e o fornecido pela rede (Equação 6); se erro > erro permitido, então:
 - (c) Calcule o termo de correção do erro para camada *output* (Equação 14)
 - (d) Calcule as variações do peso e do *bias* (equações 11 e 12)
 - (e) Atualize as conexões entre as camadas *hidden* e *output* (equações 7 e 8)
 - (f) Calcule o termo de correção do erro da camada *hidden* (Equação 16)
 - (g) Calcule as variações do peso e do *bias* (Equações 9 e 10)

- (h) Atualize as conexões entre as camadas *input* e *hidden* (Equações 7 e 8)
- (i) Volte ao passo (a)

2.3: Seleção do Conjunto de Treinamento

A performance da rede neural MLP é fortemente dependente do conjunto de dados usado no treinamento, o qual deve possibilitar a melhor representação possível do domínio do problema. Para tanto, esse conjunto deve tentar incluir representantes de todas as variáveis importantes, porém, deve ter o menor número de *inputs* possível, para que se possa trabalhar com a rede mais simples possível, isto é, a que apresente a menor quantidade de conexões entre os neurônios. Além disso, é necessário que se tenha uma quantidade suficiente de exemplos de treinamento.

Existem fórmulas para estimar o tamanho da amostra de treinamento que seja suficiente para um bom desempenho de generalização. No entanto, verifica-se com frequência que existe uma diferença numérica imensa entre o tamanho da amostra realmente necessária e aquela prevista pelas fórmulas (HAYKIN, 2001).

CHTIOUI *et alii* (1999), por exemplo, utilizaram 1920 exemplos de treinamento para determinar o teor de umidade em folhas a partir de fatores micrometeorológicos como velocidade do vento. EBUBE *et alii* (2000) utilizaram 15 conjuntos de treinamento em redes neurais para predição de propriedades físico-químicas de polímeros amorfos como temperatura de transição vítrea. VERT *et alii* (2000) demonstraram a possibilidade de construção de um modelo de redes neurais para a definição da atividade antibacterial de substâncias a partir de suas estruturas utilizando 465 exemplos de treinamento.

2.4: Pré-Processamento dos Dados

Para se trabalhar com redes neurais, não é necessário o estudo dos modelos matemáticos que descrevem o sistema em estudo. No entanto, o usuário precisa conhecer esse sistema para poder decidir quais são as variáveis importantes, que serão usadas como

neurônios da camada *input*. Após definição dessas variáveis e seleção do conjunto de treinamento, antes de iniciar o treinamento da rede, é preciso fazer um pré-tratamento dos dados. Os tipos principais de pré-tratamento são mostrados a seguir.

- Aleatorização: consiste na disposição aleatória dos conjuntos. É importante para evitar que a rede neural aprenda alguma informação errônea devido à forma como os dados foram arranjados. A aleatorização também pode ser realizada a cada nova iteração.
- Escalonamento: evita que os valores de maior magnitude exerçam um efeito muito grande durante a etapa de treinamento e, portanto, que algumas variáveis tenham maior importância que outras (SWINGLER, 1996; BAUGHMAN e LIU, 1995). Usualmente, os dados da camada *input* (X) são escalonados na faixa de 0 a 1, e os dados da camada *output* (Y), na faixa de 0,1 a 0,9, como mostram as Equações 18 e 19, respectivamente. Segundo HOSKINS e HIMMELBLAU (1988), quando os dados da camada *output* são escalonados na faixa de 0 a 1, a função de transferência pode gerar valores de peso muito grandes, o que ocasiona erros de truncamento. O procedimento inverso é realizado para converter as variáveis preditas para os valores originais.

$$X_{escal} = \frac{X - X_{menor}}{X_{maior} - X_{menor}} \quad (18)$$

$$Y_{escal} = \frac{Y - Y_{menor}}{Y_{maior} - Y_{menor}} 0,8 + 0,1 \quad (19)$$

Sendo: X_{escal} = *input* escalonado

Y_{escal} = *output* escalonado

- **Centralização:** consiste na subtração do valor médio da coluna e divisão do resultado pelo desvio padrão calculado. Esse procedimento pode minimizar os efeitos dos possíveis *outliers* (valores muito distantes da média da variável em questão), sem que eles sejam arbitrariamente eliminados (BOGER, 1997, SWINGLER, 1996).

2.5: Delta-Barra-Delta

Uma modificação do algoritmo de *backpropagation* que tem sido citada na literatura é o algoritmo delta-barra-delta. Esse algoritmo foi desenvolvido com o intuito de acelerar a convergência do treinamento através de adaptações sucessivas da taxa de aprendizagem e se baseia em quatro pontos (HAYKIN, 1994):

- Para cada peso da rede neural deve existir uma determinada taxa de aprendizagem.
- A taxa de aprendizagem deve variar de uma iteração para outra.
- Quando a derivada da função erro com respeito a um peso apresenta o mesmo sinal algébrico durante várias iterações consecutivas, a taxa de aprendizagem para esse peso particular deve ser aumentada.
- Quando o sinal algébrico da derivada da função erro com respeito a um peso sináptico sofre variação durante várias iterações consecutivas, a taxa de aprendizagem para esse peso particular deve ser diminuída.

Sejam $W_{ij}(n)$ o valor do peso que conecta o neurônio i ao neurônio j , medido na iteração n , e $\eta_{ij}(n)$ a taxa de aprendizagem associada a esse peso nessa iteração. A atualização da taxa de aprendizagem pelo algoritmo delta-barra-delta é definida pelas regras a seguir (HAYKIN, 1994):

$$\eta_{ij}(n) = \eta_{ij}(n-1) + \Delta\eta_{ij} \quad (20)$$

$$\Delta\eta_{ij} = \begin{cases} k & \text{se } S_{ij}(n-1)D_{ij}(n) > 0 \\ -\beta\eta_{ij} & \text{se } S_{ij}(n-1)D_{ij}(n) < 0 \\ 0 & \text{se } S_{ij}(n-1)D_{ij}(n) = 0 \end{cases} \quad (21)$$

Na Equação 21, k e β são constantes, sendo que, ao assumirem o valor zero, a taxa de aprendizagem assume um valor constante ao longo das iterações, como acontece no algoritmo de *backpropagation* padrão.

O termo $D_{ij}(n)$ representa a derivada parcial da superfície de erro com relação ao peso, como mostra a Equação 22.

$$D_{ij}(n) = \frac{\partial E(n)}{\partial w_{ij}(n)} \quad (22)$$

O termo $S_{ij}(n)$ representa uma soma das derivadas passada e atual da superfície de erro com relação ao peso, sendo que ξ é uma constante positiva:

$$S_{ij}(n) = (1-\xi)D_{ij}(n-1) + \xi S_{ij}(n-1) \quad (23)$$

CAPÍTULO 3: COMPÓSITOS POLIMÉRICOS

Atualmente, são inúmeras as possibilidades de aplicação dos compósitos poliméricos. Como exemplo, pode-se citar o caso das plataformas de extração petrolífera da Petrobras. Hoje, esse tipo de material é usado principalmente nos pisos das plataformas da Bacia de Campos; na plataforma de Pampo, 20% das grades de piso em aço já foram substituídas, representando uma economia anual de R\$ 600 mil. Além dos pisos, o plástico reforçado já está sendo utilizado em corrimões, calhas para a passagem de instalações elétricas, tubos de esgoto e água potável, tubulações em geral e guarda-corpos (barra de proteção na borda de navios) das plataformas. Conforme mencionado na Revista do Plástico Reforçado (2000), em pouco tempo, pretende-se aproveitar os compósitos também em outras estruturas como escadas e passarelas.

Vários aspectos dos compósitos, incluindo a sua própria definição, podem variar de autor para autor. Segundo AGARWAL e BROUTMAN (1990), a palavra compósito significa “que consiste de duas ou mais partes distintas” e portanto um material formado por duas ou mais fases, as quais apresentam propriedades diferentes, pode ser considerado um compósito. Conforme citado em FELDMAN (1989), um material compósito pode ser definido também como qualquer substância a qual é feita pela combinação física de dois ou mais materiais para produzir um sistema multifásico que vai apresentar propriedades físicas diferentes das dos materiais de origem, mas no qual os constituintes retêm suas identidades.

CHAWLA (1987) coloca a questão de uma maneira interessante ao observar que “praticamente tudo nesse mundo é um material compósito”. Em seu livro, esse autor assume que um material é um compósito quando ele satisfaz as seguintes condições: (i) é fabricado (portanto, materiais de ocorrência natural como a madeira, são excluídos), (ii) consiste de duas ou mais fases física e/ou quimicamente distintas, adequadamente arranjadas ou distribuídas e com uma interface separando-as e (iii) apresenta características não observadas em nenhum dos componentes isolados.

Se uma ou mais das fases dispersas pode ser distinguida macroscopicamente ou se mais do que uma fase contínua está presente, então o material é considerado um macrocompósito. Caso contrário, o material pode ser considerado um microcompósito.

Com base nessas definições, compósitos poliméricos podem ser descritos como macrocompósitos nos quais pelo menos a matriz é um polímero (FELDMAN, 1989).

De uma maneira geral, um compósito é formado por uma matriz (fase contínua) e um reforço (fase descontínua). Uma vez que muitos tipos de matrizes e reforços podem ser utilizados e arrançados de diversas maneiras, muitos métodos de fabricação de compósitos são descritos na literatura. A escolha do método mais adequado depende inicialmente de uma avaliação dos constituintes do compósito.

3.1: Classificação dos Materiais Compósitos

Os materiais compósitos podem ser classificados de diferentes maneiras. A Figura 5 ilustra uma dessas possíveis classificações, feita com base no tipo de matriz, que divide os compósitos em metálicos, cerâmicos, poliméricos e biológicos.

A matriz é o material que envolve o reforço. O seu papel é transferir a carga aplicada para esse reforço e proteger a sua superfície do ataque do ambiente e de danos devido ao manuseio. Se o reforço é fibroso, a matriz também pode ser responsável por manter as fibras unidas e alinhadas em uma certa direção. É a matriz quem dita a faixa de temperatura operacional e as demais condições de processabilidade do compósito.

As principais características requeridas para a matriz são (ILSCHNER *et alii*, 1986):

- Ser quimicamente compatível com o reforço.
- Ser compatível com o método de fabricação.
- Ser estável nas condições de uso da peça fabricada.

Matrizes poliméricas, que constituem o assunto de interesse desse trabalho, podem ser divididas em resinas termoplásticas e termorrígidas. Compósitos de matriz polimérica também são chamados de plástico reforçado, FRP (do inglês *fiber reinforced plastic*), materiais plásticos compostos, PMC (do inglês *polymer matrix composite*), entre outras denominações.

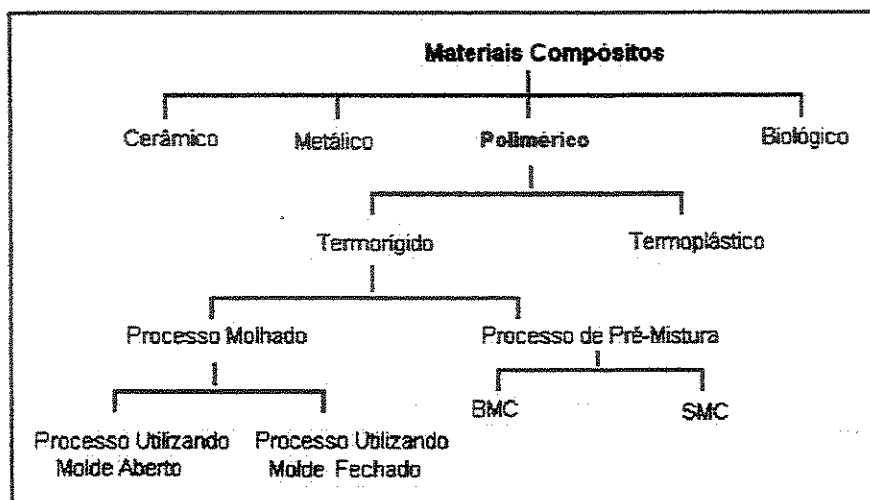


Figura 5: Classificação dos Compósitos de acordo com o Tipo de Matriz.

MATTHEWS e RAWLINGS (1996) também incluem as borrachas (por exemplo SBR) como matrizes para os compósitos poliméricos. Exemplos de peças são barcos infláveis, esteiras de transporte e revestimento de cabos resistentes ao fogo.

Outra classificação para os compósitos pode ser feita de acordo com o tipo de reforço, como mostra a Figura 6. Segundo essa figura, a primeira distinção entre os compósitos refere-se à natureza do reforço (fibroso ou particulado).

Se o reforço for um material não fibroso, independente da forma regular ou irregular que apresente (esférico, cúbico, etc) o compósito é chamado de particulado.

Conforme mostra a Figura 6, os materiais fibrosos podem ser classificados em compósitos de camada simples ou única e compósitos multicamada. Em ambos os casos, o compósito é formado por várias camadas e é denominado tipo camada simples se todas elas apresentam a mesma orientação e propriedade. Uma definição comum para as fibras requer que seu comprimento seja pelo menos 100 vezes seu diâmetro (BILLMEYER Jr., 1984).

Em um compósito tipo multicamada, a orientação de cada camada ou lâmina pode ser variada de acordo com o *design* desejado. Se todas as camadas forem formadas pelo mesmo material, o compósito é chamado de laminado, caso contrário, é denominado híbrido (por exemplo, um compósito híbrido pode possuir camadas de epóxi e fibra de vidro e de epóxi e fibra de carbono). Também é possível, porém pouco comum, encontrar materiais híbridos que apresentem misturas de fibras em suas camadas simples.

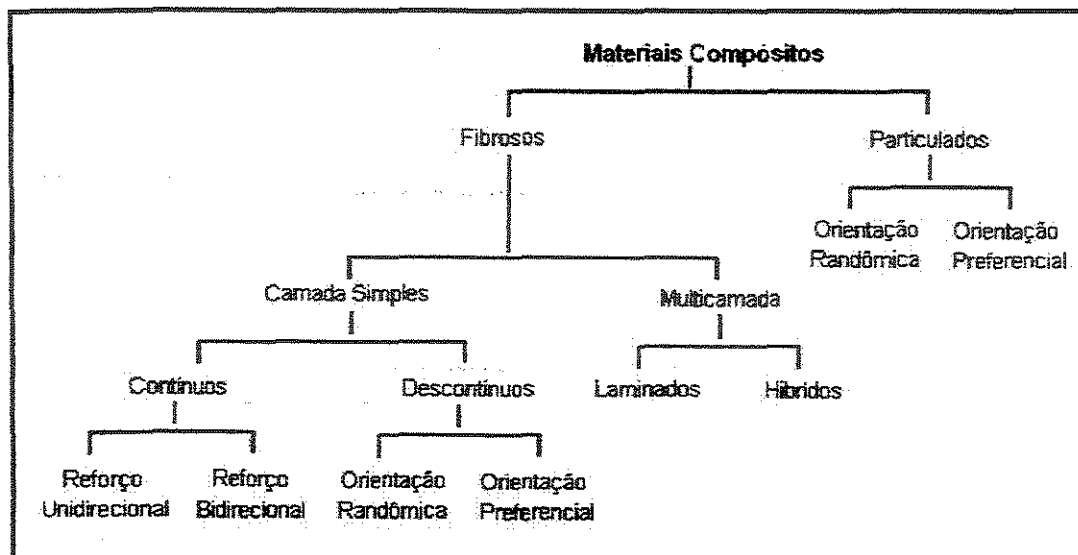


Figura 6: Classificação dos Compósitos de Acordo com o Reforço (AGARWAL e BROUTMAN, 1990; MATTHEWS e RAWLINGS, 1996).

Em um compósito de camada simples, as fibras podem ser longas ou curtas, comparadas com suas dimensões globais. Compósitos com fibras longas (> 10 mm) são denominados contínuos e os de fibras curtas são denominados descontínuos. Compósitos descontínuos podem ainda ser considerados como aqueles nos quais o comprimento da fibra afeta a propriedade do compósito.

As fibras contínuas em um material tipo camada simples podem ser alinhadas em uma certa direção, formando compósitos unidirecionais. O reforço contínuo em uma camada simples também pode ser disposto em uma segunda direção, para fornecer propriedades mais balanceadas (AGARWAL e BROUTMAN, 1990).

Além da matriz e do reforço, uma outra parte importante do compósito é a interface, que pode ser definida como a região onde a matriz é quimicamente ligada ou mecanicamente encaixada ao reforço. As propriedades dos compósitos são influenciadas pelo grau de ligação interfacial entre o reforço e a matriz. Logo, a aplicação de um terceiro componente para modificação da superfície do reforço em compósitos (agente de acoplagem) tende a melhorar as propriedades mecânicas e a resistência química desses materiais. O exemplo mais comum de agente de acoplagem é o silano, normalmente utilizados em compósitos de fibra de vidro, e cuja fórmula é $X_3Si(CH_2)_nY$, onde n varia de

0 a 3, Y é um grupo compatível com a matriz polimérica e X é um grupo hidrolizável (AGARWAL e BROUTMAN, 1990).

3.2: Matrizes Poliméricas

Entre as vantagens que os compósitos poliméricos podem apresentar estão: redução de peso (o que diminui os custos de montagem e facilita a instalação da peça), resistência à corrosão e a temperaturas elevadas, propriedades não-magnéticas (desejável em certas áreas hospitalares e onde operam radares e antenas), resistência à degradação ambiental (o que é particularmente importante na construção civil), fabricação de peças com redução no número de partes (permitindo economia com elementos de ligação, tempo e mão-de-obra), possibilidade de fabricação de peças com propriedades feitas sob medida, e redução dos custos de fabricação, quando comparados aos materiais convencionais de engenharia. Segundo EDWARDS (1998), os custos das matérias-primas podem ser mais elevados que os metais por exemplo, mas os custos de processamento são geralmente mais baixos.

No entanto, alguns compósitos de matriz polimérica podem apresentar alto coeficiente de expansão térmica e, portanto, instabilidade dimensional, menor temperatura máxima de trabalho, além de serem sensíveis à radiação e umidade (inchamento do material).

Dentre os compósitos poliméricos, estima-se que mais que 3/4 são fabricados com matriz termorrígida ou termofixa (MATTHEWS e RAWLINGS, 1996) que são aquelas que formam ligações cruzadas durante o processo de cura. Apesar de apresentar a desvantagem de se degradar com o aquecimento (não podem ser remodeladas), esse tipo de resina pode ser utilizado em temperaturas mais elevadas, uma vez que apresenta uma faixa de temperatura de serviço entre 50 e 450°C (para os termoplásticos, tem-se 25 a 230°C, conforme citado em ILSCHNER *et alii*, 1986). Outras vantagens em relação aos termoplásticos são a maior rigidez e a maior resistência ao ataque químico (MATTHEWS e RAWLINGS, 1996).

As resinas termorrígidas mais utilizadas são: poliéster, epóxi, éster vinílico, fenólica e poliimida. Dentre essas, as duas principais resinas utilizadas como matrizes para os

plásticos reforçados são as resinas poliéster e epóxi. As resinas epóxi são superiores aos poliésteres particularmente com respeito à adesão com uma ampla variedade de fibras, além de maior resistência à umidade, resistência química (AGARWAL e BROUTMAN, 1990) e resistência térmica, uma vez que possui temperatura de transição vítrea superior. Por outro lado, os poliésteres são muito mais baratos que as resinas epóxi e geralmente curam mais rápido.

A resina éster vinílico é obtida a partir da reação de uma resina epóxi com ácido acrílico ou metacrílico e suas propriedades podem ser variadas através da utilização de diferentes resinas epóxi. Comparada a essa resina, a éster vinílico geralmente apresenta melhor resistência química e maiores temperaturas de serviço. A resina éster vinílico está entre as resinas poliéster e epóxi quanto à performance e ao custo (EDWARDS, 1998).

Resinas poliéster são produzidas por uma reação de condensação entre um glicol (etileno, propileno, dietileno glicol) e um ácido dibásico insaturado (maleico ou fumárico), como mostra a Figura 7. O monômero polimerizável (reativo), como o estireno, que também contém dupla ligação, age como um agente de ligação cruzada unindo moléculas de poliéster adjacentes nos seus pontos de insaturação; o monômero também age como um diluente, reduz a viscosidade e facilita o processamento. Pode-se adicionar um acelerador para tornar a reação mais rápida, sendo que alguns fornecedores vendem a resina com o acelerador incluído (resinas pré-aceleradas). Além do acelerador, existem vários outros aditivos que podem ser adicionados, como inibidores e aditivos para controle de encolhimento (EDWARDS, 1998).




Figura 7: Reação de Formação da Resina Poliéster (AGARWAL e BROUTMAN, 1990).

As vendas de resinas poliéster no Brasil tiveram um aumento médio de 5% nos últimos anos, impulsionado, principalmente pela construção civil, seguido pelas áreas de pultrusão e corrosão. No entanto, o consumo per/capita no Brasil ainda é bastante inferior

ao consumo externo. Para se ter uma idéia, segundo a Revista do Plástico Reforçado (2000) a quantidade atual de resina consumida pela indústria brasileira representa o volume americano na década de 60.

A Tabela 2 abaixo mostra alguns dos setores do mercado brasileiro de resina poliéster insaturado, que movimentou um total de 84 mil toneladas/ano em 1999.

Tabela 2: Mercado Brasileiro de Resinas Poliéster Insaturado (Revista do Plástico Reforçado, 2000).

Setor	Mil Toneladas/Ano
Construção Civil	22
Transporte	15
Indústria Química	14
Eletroeletrônica	5
Mobiliária	2,5
Náutica	2,5

Resinas epóxi podem se apresentar de diversas formas, desde líquidos viscosos até sólidos de elevado ponto de fusão. São normalmente vendidas com um segundo constituinte, um endurecedor ou agente de ligação cruzada (aminas alifática ou aromáticas e anidridos), a ser adicionado. Através da combinação de diferentes resinas e endurecedores, é possível obter uma ampla faixa de propriedade. As maiores limitações desses materiais são a perda de propriedades mecânicas a altas temperaturas, especialmente na presença de umidade, e o custo elevado.

As resinas fenólicas são as mais antigas resinas termorrígidas utilizadas industrialmente. São formadas pela reação entre fenol e aldeído e apresentam boa resistência ao fogo, mas mostram dificuldade para pigmentação.

As poliimidas são formadas pela condensação de dianidrido e amina aromática. Os ciclos de processamento para esse material são longos e ocorrem a temperaturas elevadas. Como vantagem, as peças fabricadas com essa resina geralmente podem operar em temperaturas elevadas.

A utilização de polímeros termoplásticos como matriz de compósitos teve início na década de 70, com o objetivo de combinar as propriedades de reforço das fibras com a formabilidade desse tipo de polímero (FELDMAN, 1989). Entre os polímeros

termoplásticos que têm sido utilizados como matriz para compósitos podem ser citados: poliolefinas, polímeros vinílicos e policarbonatos.

3.3: Fibras

As fibras constituem o reforço mais utilizado nos plásticos reforçados, sendo que o tipo mais freqüentemente empregado é a fibra de vidro. Além dessa, também são bastante utilizadas fibras de carbono, grafite e aramida. A literatura também cita a utilização de fibras de metal ou metal revestido (EDWARDS, 1998, CHAWLA, 1987).

A fibra de vidro é uma mistura de óxidos, sendo o principal deles a sílica. Existem várias grades comerciais de fibra de vidro (A, C, D, E, L, R e S) e a mais usada é a tipo E, que representa cerca de 95% da produção de fibra de vidro.

A fibra de aramida abrange as fibras de poliamida aromática, que podem ser produzidas através dos processos *melt*, *dry* e *wet spinning* (detalhes sobre os métodos de fabricação de fibras poliméricas podem ser encontrados em BILLMEYER Jr, 1984). O Kevlar é um tipo muito famoso de fibra de aramida produzido comercialmente pela DuPont e sua estrutura química consiste de unidades aromáticas *para*-substituídas. Existem três tipos principais de fibras de Kevlar: Kevlar, Kevlar 29 e Kevlar 49 (EDWARDS, 1998).

A fibra de carbono é produzida através da pirólise controlada de um precursor, como por exemplo *rayon* e poliacrilonitrila. Os estágios da pirólise incluem oxidação, carbonização e grafitização, sendo que através do ajuste da temperatura do processo é possível produzir uma ampla faixa de fibras de carbono, com diferentes propriedades mecânicas. Os três principais tipos de fibra de carbono são: tipo I, tipo II e tipo III. As fibras de carbono apresentam um teor de carbono entre 80 e 95% enquanto as fibras de grafite possuem 99% de carbono (AGARWAL e BROUTMAN, 1990).

3.4: Aspectos Econômicos

Um dos setores da economia que tem crescido com maior velocidade em todo o mundo é o dos plásticos, que em 1999, só no mercado norte-americano, movimentou cerca de 304 bilhões de dólares, empregando mais de 1,5 milhões de pessoas (Revista do Plástico Reforçado, 2000). Inseridos nesse contexto, encontram-se os materiais plásticos reforçados, representando uma parcela importante desse segmento.

Conforme mostra a Tabela 3, o setor dos transportes é responsável por 29% da demanda mundial do mercado de compósitos poliméricos, representando um mercado que mistura todos os tipos de combinações de materiais e processos, com um amplo caminho para o crescimento. KARBHARI e ZHAO (2000) discutem as possibilidades de aplicação dos compósitos poliméricos na construção civil (por exemplo, na construção ou reparo de pontes e edifícios). Na indústria química, algumas das utilizações são tubos, dutos, tanques, reservatórios, grades de piso, escadas e revestimentos anticorrosivos.

Estima-se que existam hoje cerca de 1500 companhias ligadas à indústria de plásticos reforçados no Brasil (JACOB, 1999).

Tabela 3: Demanda Mundial do Mercado de Compósitos Poliméricos em 1999 (Revista do Plástico Reforçado, 2000).

Setor	% do Mercado
Transporte	29
Construção	19
Indústria/Agricultura	16
Elétrica/Eletrônica	13
Móveis e Bens Semi-Duráveis	9
Equipamentos Militares	8
Recreação	6

A indústria moderna de compósitos de matriz polimérica teve início na década de 40, com a utilização das estruturas de polímero fenólico e fibra de vidro. Os anos entre 1940 e 1960 constituíram um período onde os métodos de fabricação eram o interesse predominante (a maioria das técnicas utilizadas atualmente é derivada desse período). Entre 1960 e 1970, cresceu o interesse pelo estudo das propriedades (FELDMAN, 1989).

Apesar de ser o líder no mercado de compósitos da América do Sul, o mercado brasileiro ainda está muito distante do volume norte-americano e europeu, como mostra a Tabela 4. Em 1999, a indústria brasileira de compósitos poliméricos atingiu 83 mil toneladas, e espera-se que tenha a maior taxa de crescimento na região para os anos de 2000/2001. Outros países da América do Sul com importantes indústrias de compósito são a Argentina e Venezuela, que atingiram 31 e 12 mil toneladas, respectivamente, nesse mesmo ano (JACOB, 1999).

Tabela 4: Mercado Global de Compósitos no ano 2000 (Revista do Plástico Reforçado, 2000).

Localidade	% do Mercado
América do Norte	46
Europa	27
Ásia	24
América do Sul	3

No âmbito global, as indústrias de materiais compósitos poliméricos estão em contínuo crescimento. Entre 1991 e 1998, o volume do mercado internacional manteve, em média, 5% de ampliação. Em 1998, a produção alcançou a marca de cerca de 5,5 milhões de toneladas nos três continentes.

A indústria brasileira de plásticos reforçados é constituída, na sua maioria, por fabricantes de peças (66%), como mostra a Tabela 5. Os revendedores e fabricantes de matérias-primas representam, cada um, cerca de 5%.

Tabela 5: Indústria Brasileira de Compósitos Poliméricos (Revista do Plástico Reforçado, 2000).

Indústria	%
Fabricantes de Peças	66
Empresas que Utilizam Peças de Plástico Reforçado em seus Produtos Finais e Matérias-Primas para Consertos Próprios	15
Empresas que Prestam Serviços	10
Fabricantes de Matérias-primas, Produtos Auxiliares e Equipamentos	5
Revendedores de Matérias-Primas	4

O faturamento anual das empresas de compósitos no Brasil é bastante diversificado. Segundo a Revista do Plástico Reforçado, em 1999, quase a metade dos representantes brasileiros (42%) faturou cerca de 250 mil reais, enquanto que outra fatia importante desse mercado (29%) obteve um montante de recursos bem maior, aproximando-se de 2,5 milhões de reais por ano. O faturamento alcançado pela indústria brasileira dividiu-se, ainda, conforme pode ser visto na Tabela 6, em 750 mil reais correspondente a 14% das empresas, e um número mais restrito (10%) atingindo 10 milhões de reais.

Tabela 6: Faturamento Médio Anual das Empresas Brasileiras em 1999 (Revista do Plástico Reforçado, 2000).

Faturamento (R\$)	Empresas que Atingiram o Faturamento (%)
250 mil	42
2,5 milhões	29
750 mil	14
10 milhões	10
25 milhões	5

3.5: Métodos de Fabricação

A fabricação de produtos compósitos geralmente requer as seguintes operações básicas (ILSCHNER *et alii*, 1986):

- Envolver o reforço com a matriz, enquanto esta está em um estado não rígido.
- Arranjar o reforço em padrões selecionados e orientados.
- Solidificar a matriz sob condições que impeçam o reforço de se movimentar.
- Transformar o material compósito em uma peça.

A escolha do tipo de material a ser utilizado e da forma que ele vai adquirir depende da característica e da performance que se deseja para a peça final, sendo o custo o menor possível.

A escolha da tecnologia de fabricação também é influenciada por aspectos como geometria da peça, taxa de produção, confiabilidade e custo do método, facilidade de obtenção da matéria-prima, e complexidade operacional.

Para a fabricação de peças de matriz termorrígida reforçadas com fibras contínuas, é necessário impregnar o reforço com a resina ou colocar fibras pré-impregnadas em um molde, podendo-se aplicar calor e pressão por um determinado tempo para cura do material. A temperatura aplicada durante a etapa de cura fornece o calor necessário para iniciar e manter as reações químicas da resina que ocasionam as desejadas mudanças na estrutura molecular. A pressão que é aplicada em alguns métodos de fabricação possibilita a compressão das bolhas de vapor (LOOS e SPRINGER, 1983).

Um dos grandes desafios na obtenção de peças de qualidade e a um baixo custo reside na seleção do ciclo de cura (seqüência de temperatura e pressão aplicadas durante o processamento por um determinado tempo), uma vez que este afeta significativamente a performance do produto final (LOOS e SPRINGER, 1983, LEE e SPRINGER, 1988). O ciclo de cura deve ser cuidadosamente selecionado para cada aplicação, devendo atender às seguintes condições: (i) a temperatura no interior do material não deve exceder um determinado valor máximo em nenhum momento ao longo do ciclo, para evitar a degradação térmica, (ii) o tempo de processamento deve ser o menor possível e (iii) o material deve ser curado completa e uniformemente. A escolha do ciclo de cura ótimo não é uma tarefa trivial, uma vez que as reações de cura são acompanhadas de complexos fenômenos físicos e mecânicos que ocorrem no material compósito, os quais ainda não são totalmente compreendidos (GOROVAYA e KOROTKOV, 1996).

A escolha do ciclo de cura pode ser feita empiricamente, através da cura de pequenas peças e posterior avaliação da qualidade das mesmas. Conforme apontado em (LOOS e SPRINGER, 1983), essa metodologia apresenta várias desvantagens. Outra possibilidade é utilização de modelos analíticos. Uma vez que a modelagem matemática do processo é complexa, envolvendo muitas variáveis, uma alternativa interessante, como será mostrado adiante, é a aplicação de redes neurais.

Entre os vários métodos de fabricação de compósitos de matriz termorrígida pode-se citar pultrusão, *spray-up*, *hand-lay-up*, moldagem sob pressão, a vácuo e com autoclave, BMC (*bulk moulding compound*), SMC (*sheet molding compound*) e *filament winding*.

A seguir, serão descritos a título de ilustração os seguintes métodos de fabricação de compósitos de matriz termorrígida: *hand lay-up*, *spray-up*, pultrusão, SMC e *filament winding*, que constitui o assunto de interesse desse trabalho. Os métodos de pultrusão e SMC serão descritos porque existem trabalhos da literatura que aplicaram a técnica de redes neurais na modelagem desses processos, e os métodos de *hand lay-up* e *spray-up* serão abordados porque, além do *filament winding*, são técnicas também utilizadas pela empresa Polyplaster.

Alguns métodos utilizados na produção de compósitos de matriz termorrígida também podem ser aplicados, com certas adaptações, na fabricação de compósitos de matriz termoplástica (pultrusão e *filament winding* são exemplos). A principal diferença entre os métodos é que para os termoplásticos não há a necessidade de ciclos de cura, o que reduz o tempo de processamento; no entanto, o custo final da peça pode ser mais elevado, uma vez que as resinas termoplásticas podem ser entre 1,5 e 4 vezes mais caras que as termorrígidas (GOLDSWORTHY, 1986).

3.5.1: *Hand Lay-up*

A técnica de *hand lay-up*, *contact lay-up* ou laminação manual é a mais antiga e simples, e uma das mais comumente empregadas na fabricação de produtos compósitos, permitindo a obtenção de peças de diversas dimensões. Esse método é indicado quando o volume de produção é baixo e a utilização de outras formas de produção não seria vantajosa devido aos custos. Como aplicações típicas podem ser citados barcos, cascos de navios, tanques, dutos, piscinas, móveis e folhas planas (AGARWAL e BROUTMAN, 1990).

Nesse processo, conforme ilustra a Figura 8, uma camada ou um conjunto de camadas de reforço (pré-cortados no padrão desejado) são posicionados em um molde e impregnados com o polímero líquido. Essa tecnologia usa apenas uma peça de molde (que define o contorno externo ou interno da peça) e é bastante simples, o que pode torná-la atrativa do ponto de vista econômico (FELDMAN, 1989). A resina mais comumente empregada nessa técnica é a de poliéster, sendo a cura a temperatura ambiente (MATTHEWS e RAWLINGS, 1996).




Figura 8: Laminação Manual (FELDMAN, 1989).

O molde pode conter uma camada de silicone, PVA ou graxa, que são adicionados para facilitar a sua liberação após a formação da peça. A escolha do “agente de liberação” depende do tipo de superfície a ser moldada, do grau de brilho desejado para o produto final e se pinturas ou outros acabamentos secundários serão requeridos. Quando se deseja que a superfície da peça tenha uma boa aparência ou seja protegida, é preciso a aplicação de uma camada de resina especialmente formulada, chamada de revestimento com gel. Essa resina, que em muitos casos é poliéster, é aplicada ao molde e vai se tornar a superfície mais externa da peça produzida.

Entre as vantagens da técnica estão a simplicidade e a possibilidade de obtenção de peças complexas e grandes. Além disso, é uma técnica relativamente barata. No entanto, a taxa de produção é baixa, é uma técnica laboriosa, a qualidade da peça é dependente da habilidade do operador, a uniformidade (em uma única peça ou de uma peça para outra) é difícil, apenas uma das superfícies externas da peça será bem acabada, pode ter longos ciclos de cura, as propriedades mecânicas da peça não são boas uma vez que o método emprega baixa quantidade de reforço (em torno de 30% em volume) e é difícil remover todo o ar que fica retido.

3.5.2: *Spray-up*

Na técnica de *spray-up* (conhecida também como aspersão ou jato contínuo), como ilustra a Figura 9, o reforço (geralmente fibra de vidro) é continuamente alimentado em um dispositivo (*spray gum*) que corta as fibras em um comprimento conveniente (por exemplo, 5 cm). As fibras resultantes são jogadas na corrente de resina que também está entrando no

spray gum, a qual é aspergida em um molde. O *spray gum* pode conter dois orifícios, para a resina e aditivos.




Figura 9: *Spray-up* ou Jato Contínuo (AGARWAL e BROUTMAN, 1990).

Após atingir a espessura desejada, a área exposta é alisada (em geral, manualmente), o que também é feito para remover bolhas de ar e compactar as fibras, consolidando o compósito. O método *spray-up* é uma forma semi-automática de *hand lay-up*. No entanto, esse método só produz compósitos de fibra curta, enquanto o método de *hand lay-up* pode ser usado com fibras contínuas. Entre as vantagens tem-se (FELDMAN, 1989): é uma técnica simples e relativamente barata, o equipamento de *spray* é portátil, a taxa de produção pode ser maior que a do processo de laminação manual e os custos de produção podem ser reduzidos devido ao volume de produção mais elevado. Algumas das desvantagens encontradas na técnica são: a peça vai apresentar apenas uma superfície bem acabada, a uniformidade da peça depende da habilidade do operador e não é um método economicamente viável para grandes volumes de produção.

3.5.3: Pultrusão

Pultrusão é um método de fabricação de materiais compósitos em perfis contínuos e que apresentam seção transversal constante. Essa técnica apresenta algumas semelhanças com a extrusão, com a diferença que, na pultrusão, o produto é puxado do molde ao invés de ser forçado a sair devido à pressão aplicada. O processo consiste em puxar fios

contínuos através de um banho de resina e, após, através de um molde, onde a peça ganha uma forma parcial e o excesso de resina e/ou ar é removido. Em seguida, o material passa por um compartimento aquecido, onde é curado (AGARWAL e BROUTMAN, 1990).

O equipamento de pultrusão, conforme ilustra a Figura 10, consiste basicamente dos seguintes elementos: bobinas de fios, banho de resina, molde aquecido, mecanismo para puxar o material e mecanismo de corte do material.




Figura 10: Pultrusão (AGARWAL e BROUTMAN, 1990).

A velocidade com que o material é puxado pode variar desde poucos cm/min até m/min e mais do que um molde aquecido pode ser empregado para aumentar a produção. O método de pultrusão permite obter diversos tipos de perfis, em diferentes comprimentos, espessuras e diâmetros, como por exemplo tubos redondos, tubos quadrados, barras chatas, placas planas, perfis em U, I, Y e H. Dessa forma, é possível a obtenção de vários tipos de peças, como por exemplo escadas e grades.

O processo de pultrusão é mais adequado para resinas termorrígidas que sofrem cura sem produzir um subproduto de condensação (poliéster e epóxi). Esse processo também pode ser aplicado a polímeros termoplásticos; nesse caso, é necessária a utilização de um equipamento especial de impregnação para fundir ou amolecer a resina.

A principal diferença entre os sistemas de pultrusão para resinas termorrígidas e termoplásticas está nas temperaturas do banho de impregnação de resina e do molde. A pultrusão para resinas termoplásticas utiliza um banho de resina fundida e um molde que resfria e dá a forma final à peça. Uma dificuldade desse processo reside na elevada

viscosidade das resinas termoplásticas em comparação com as termorrígidas, o que limita a taxa de produção.

WILCOX e WRIGHT (1998) publicaram um trabalho que aplica redes neurais com sucesso na modelagem e otimização do processo de pultrusão utilizando dados reais no treinamento das redes. Como *inputs* da rede foram consideradas condições operacionais (como temperatura do molde) e características do material (como viscosidade da resina). As saídas da rede representaram medidas de qualidade e propriedades mecânicas das peças.

3.5.4: SMC

O processo SMC (*sheet molding compound*) de moldagem por compressão que permite a obtenção de lâminas de material compósito de matriz termorrígida é ilustrado na Figura 11. Esse método geralmente utiliza resina poliéster e 20 a 35 % de fibra de vidro cortada com um comprimento entre 21 e 55 mm (AGARWAL e BROUTMAN, 1990).

Conforme mostra a Figura 11, inicialmente um filme contínuo de celofane ou polietileno é recoberto com uma resina adequadamente formulada, na qual é depositada uma camada de reforço. Em seguida, um outro filme, similarmente recoberto com a resina, é colocado sobre o reforço, formando um "sanduíche". O conjunto formado passa então por uma série de rolos compressores e é enrolado em uma bobina final. A lâmina formada, após a remoção dos filmes de envoltura, pode ser colocada em um molde, pressionada e curada, para formar a peça desejada. Entre os aditivos utilizados no processo estão agentes de espessamento como óxido de cálcio ou magnésio.




Figura 11: SMC (AGARWAL e BROUTMAN, 1990).

TWU e LEE (1995) apresentaram um método, baseado em redes neurais e um algoritmo de programação não-linear, para modelagem e otimização de um processo de moldagem por compressão de uma lâmina de material compósito fabricada através do método SMC. Os autores tomaram como caso estudo uma placa cuja espessura não era constante, o que implica em transferência de calor e processos de cura distintos. Uma vez que o desejado é que a reação de cura em cada parte da peça ocorra aproximadamente ao mesmo tempo, o objetivo do trabalho foi a minimização do desvio do tempo de cura em todas as partes da peça através do *design* adequado dos canais de aquecimento. Os resultados foram comparados com técnicas estatísticas e comprovaram a eficiência do método.

O algoritmo utilizado para treinamento da rede foi o de *backpropagation* e adotou-se a função erro a ser minimizada mostrada na Equação 24, o que levou a novas relações para correção dos pesos.

$$E = -\sum_{l=1}^M \sum_{k=1}^{N_{out}} [(1 - Y_k) \ln(1 - OL_k) + Y_k \ln(OL_k)] \quad (24)$$

Sendo: E = erro de treinamento

M = número de exemplos de treinamento

N_{out} = número de neurônios na camada *output*

Y_k = valor desejado para a resposta k

OL_k = valor de saída da rede

Os autores observaram que a utilização de um valor fixo para a taxa de aprendizagem não era eficiente e empregaram um processo de ajuste dinâmico desse parâmetro durante a fase de treinamento da rede. Inicialmente, escolhia-se um valor baixo para a taxa de aprendizagem, que permanecia constante por várias iterações. O valor do erro E era então comparado com os seus valores anteriores. Quando ocorriam duas reduções consecutivas no valor de E , a taxa de aprendizagem era aumentada por uma certa quantidade; se, por outro lado, o valor do erro estava aumentando com o número de iterações, os autores reduziam a taxa de aprendizagem por um certo fator.

3.5.5: *Filament Winding*

A técnica de *filament winding*, também conhecida como filamento contínuo ou enrolamento filamentar, é empregada na produção de sólidos de revolução, como cilindros e esferas, sendo freqüentemente usada na construção de grandes tanques e tubulações industriais. A indústria petrolífera, por exemplo, é uma das grandes compradoras de tubos, que são utilizados submersos em ambiente oceânico, para transporte de água sob pressão, nas plataformas de petróleo.

Essa técnica foi inicialmente utilizada nas décadas de 40 e 50 para fabricação de componentes para as áreas militar e aeroespacial e atualmente encontra aplicações na produção de peças que vão desde tanques para armazenamento de produtos químicos até materiais esportivos. SOUTHAM (2000) cita a utilização com sucesso de tubulações (que são operadas em condições corrosivas e sob pressão) fabricadas através desse método em uma planta de tratamento de rejeitos em Adelaide, Sul da Austrália. SHEN (1995) cita a fabricação de varas de pesca. BANNISTER (2001) cita o potencial do *filament winding* para produção de tacos de golfe, que consome quase a metade do mercado total de fibras de carbono, de garrafas de gás natural comprimido para indústria automotiva e de componentes para indústria de exploração em águas profundas. Em relação a essa última área, TARNOPOL'SKII *et alii* (1999) afirmam que a exploração de depósitos de óleo e gás natural em profundidades superiores a 1500 m através de plataformas flutuantes ou semi-imersas é impossível sem a utilização de materiais compósitos, especialmente em *tendons*, que podem ser fabricados por *filament winding*. Com relação à área esportiva, JACOB (1998) também aponta o potencial desse método para a fabricação de raquetes de tênis e bicicletas, que representam grandes mercados nos Estados Unidos.

A base do *filament winding* é a disposição precisa de reforços contínuos, a altas velocidades, em padrões pré-definidos. Este processo, ilustrado na Figura 12, consiste basicamente em impregnar um feixe de fibras com uma resina e envolver este conjunto (fibra-resina) através de um molde cilíndrico (mandril) giratório aquecido, onde se dará a cura. O banho de resina ocorre em uma plataforma que se desloca com uma velocidade conhecida V , cuja relação com a velocidade angular ω de rotação do cilindro determina a orientação das fibras (ângulo ϕ). Uma tensão F é aplicada ao reforço à medida que ele é enrolado, produzindo uma pressão de compactação na camada anterior de reforço. O

desenvolvimento de equipamentos de *filament winding* controlados por computador combinado com os contínuos avanços nas fibras e resinas têm tornado esse processo cada vez mais utilizado.




Figura 12: Esquema do Processo de *Filament Winding*: (a) Visão Geral (AGARWAL e BROUTMAN, 1990) e (b) Alguns Detalhes (BANERJEE *et alii*, 1998).

Dependendo do diâmetro e comprimento de peça que se deseja fabricar, o mandril pode assumir dimensões que chegam a mais de 4 m de diâmetro e 11,5 m de comprimento, tendo um peso de mais de 45000 kg (ILSCHNER *et alii*, 1986).

A resina pode ser aplicada ao reforço seco através de um banho de resina no tempo de enrolamento (*wet filament winding*, mostrado na figura anterior) ou pode ser previamente aplicada às fibras e gelificada a um estágio B como *prepreg* (*prepreg filament winding*). O estágio B ou resitol é um estágio intermediário na reação de certas resinas termorrígidas no qual o material amolece quando aquecido, mas não dissolve ou funde totalmente. A peça pode ser curada em temperatura elevada ou em alguns casos a temperatura ambiente, sem nenhuma etapa adicional para compactação. A remoção ou dissolução do mandril e operações de acabamento completam o processo.

O método de *wet filament winding* é o mais comumente empregado na fabricação de peças cilíndricas devido ao menor custo do material empregado e da possibilidade de variação da formulação da resina para obtenção de requerimentos específicos para

diferentes peças. Além disso, o tempo de enrolamento pode ser menor que o do *prepreg winding* (BANERJEE *et alii*, 1998). A técnica de *prepreg filament winding* oferece um melhor controle da fração de volume de fibras, mas o seu custo é entre 1,5 e 2 vezes maior, isso sem contar os custos de armazenamento (MANTELL e COHEN, 1999).

Os ângulos de enrolamento empregados na construção podem ser longitudinais, helicais, circunferenciais, entre outros, como mostra a Figura 13. Fibras perfeitamente alinhadas na direção longitudinal são difíceis de serem feitas e requerem um mandril especial. Para se obter uma melhor performance, pode-se usar uma combinação de diferentes padrões de enrolamentos.




Figura 13: Alguns Padrões Usados no *Filament Winding* (AGARWAL e BROUTMAN, 1990).

Dentre os muitos processos de fabricação de materiais compósitos, o método de *filament winding* se destaca na manufatura de peças como tubos e tanques, por ser capaz de produzir peças a um baixo custo se o volume de produção e o nível de automação forem elevados. Esse processo apresenta também as seguintes vantagens (AGARWAL e BROUTMAN, 1990; PETERS e HUMPHREY, 1989): permite a obtenção de peças que apresentam elevada resistência devido ao controle da disposição das fibras, permite uma versatilidade de tamanhos, permite a obtenção de peças com elevado volume de fibras e dispensa a utilização de autoclave. Além dessas vantagens, com o *filament winding* é possível produzir várias peças ao mesmo tempo, uma vez que máquinas contendo múltiplos fusos (normalmente de 10 a 20) são comuns nas indústrias (BANNISTER, 2001).

Por outro lado, com esse método é muito difícil a fabricação de componentes com superfícies côncavas o que restringe o seu uso para a fabricação de peças com superfícies essencialmente convexas. Outras desvantagens que podem ser encontradas no processo são: a obtenção de peças com um pobre acabamento externo e a forma da peça deve permitir a

remoção do mandril (que é um componente de custo elevado), embora em alguns casos, como em cilindros para gás natural comprimido, o mandril permaneça na peça como um revestimento interno (BANNISTER, 2001).

Como o próprio nome sugere, o *filament winding* emprega filamentos contínuos, que é a forma de reforço mais barata e mais resistente, sendo que a automatização da aplicação do reforço garante menor custo de trabalho e aumenta a reprodutibilidade (SHEN, 1995). As fibras mais empregadas nessa técnica são as fibras de vidro, devido ao seu baixo custo, estabilidade dimensional e facilidade de manuseio, entre outras características (PETERS e HUMPHREY, 1989). Além delas, também são bastante empregadas as fibras de grafite e aramida (MANTELL e COHEN, 1999).

Quanto à resina, esta, para ser empregada no processo de *filament winding*, deve apresentar as seguintes características (PETERS e HUMPHREY, 1989): viscosidade menor ou igual a 2 Pa.s, *pot life* (isto é, tempo que a resina catalisada conserva a viscosidade baixa o suficiente para ser usada no processamento; também chamada *working life*) longa (preferencialmente, superior à 6 h) e baixa toxicidade. Além das resinas termorrígidas, também é possível a utilização de resinas termoplásticas, sendo que detalhes sobre esse processo (e suas limitações) podem ser encontrados em JACOB (1998).

CAPÍTULO 4: MODELAGEM DO PROCESSO DE *FILAMENT WINDING*

Uma das restrições para uma maior exploração comercial do método de *filament winding* é a dificuldade de relacionar os vários parâmetros do processo (por exemplo temperatura, tensão na fibra e ângulo de enrolamento) com a qualidade da peça final e a com eficiência do processo.

Esforços têm sido feitos no sentido de entender as interações entre variáveis, e modelos complexos do processo de *filament winding* foram desenvolvidos nas últimas décadas tanto para resinas termorrígidas quanto para resinas termoplásticas. Uma revisão sobre a modelagem do *filament winding* para resinas termoplásticas (que não é o escopo deste trabalho) pode ser encontrada em MANTELL e COHEN (1999).

Os modelos do processo de *filament winding* para resinas termorrígidas estudam a consolidação e movimentação das fibras, a cura da peça, a mudança no diâmetro dos poros, a resistência mecânica da peça, entre outros aspectos. Entre os modelos desenvolvidos estão os de AGAH-TEHRANI e TENG (1992), MAZUMDAR e HOA (1995a,b), BANERJEE *et alii* (1998), ZHAO *et alii* (2001), PARNAS e KATIRCI (2002), CALIUS e SPRINGER (1990) e LEE e SPRINGER (1990a), sendo que esse último é citado entre os mais completos e foi validado experimentalmente (LEE e SPRINGER, 1990b, CALIUS *et alii*, 1990). No próximo item, o modelo Lee-Springer será descrito, uma vez que dados obtidos através dele foram utilizados no treinamento de redes neurais.

COHEN (1997) realizou um estudo através de planejamento de experimentos (empregando cilindros de 20 polegadas de diâmetro contendo fibras de carbono e resina epóxi) para investigar a influência de alguns parâmetros do processo na qualidade e resistência de peças fabricadas por *wet filament winding*. A partir de uma triagem inicial, foram levantados cinco parâmetros importantes: tensão de enrolamento, sequência de fixação das fibras, gradiente de tensão de enrolamento e tempo de enrolamento. Entre as variáveis utilizadas para medir a qualidade das peças fabricadas por esse método foram adotadas: diâmetro externo e espessura das paredes da peça, porosidade e volume de fibra distribuído através da espessura da peça e da espessura das camadas. A porosidade pode afetar as propriedades da resina em regiões críticas como juntas, e a distribuição do volume de fibras através da espessura controla a resistência da peça.

Uma análise estatística dos dados mostrou, por exemplo, que a resistência das peças consideradas era influenciada significativamente pela sequência de fixação das fibras, tensão de enrolamento, gradiente de tensão de enrolamento, tempo de enrolamento e também pela interação entre o gradiente de tensão e o tempo de enrolamento. Em relação aos parâmetros que caracterizam a qualidade, observou-se, por exemplo, uma forte influência da tensão e do tempo de enrolamento na espessura da parede das peças (a espessura diminui com o aumento da tensão e com o decréscimo do tempo).

BANERJEE *et alii* (1998) estudaram os diferentes fenômenos físicos que ocorrem durante o processo de consolidação das fibras e seus efeitos na distribuição final da fração de volume de fibras. Os autores desenvolveram um modelo relacionando condições de processo (temperatura aplicada, tensão na fibra e velocidade de processamento) com variáveis como temperatura, grau de cura e fração de volume de fibra. O modelo é baseado na movimentação das fibras, que sofre influência da compactação do leito de fibras e da viscosidade da resina durante o enrolamento.

CHEN *et alii* (1999) escreveram o único trabalho encontrado abordando conjuntamente redes neurais e *filament winding*. Com o objetivo de otimizar duas propriedades mecânicas de peças de fibra de vidro e resina epóxi, os autores utilizaram, além das redes neurais, outras técnicas em um sistema integrado complexo: busca randômica, classificação nebulosa e teoria da informação. Desenvolveu-se uma rede neural contendo apenas três neurônios na camada *input*: ângulo de enrolamento (variando de 60 a 90°), temperatura da resina e tensão da fibra (variando de 10 a 40 N). Foram consideradas duas saídas da rede representando o resultado de testes de resistência à tensão e à compressão. O treinamento da rede empregou dois métodos: método de pseudo Gauss-Newton para pesos ligando as camada *input* e *hidden* e uma estimativa de mínimos quadrados para os pesos de saída. Foram empregadas funções de transferência lineares e tangentes hiperbólicas para os neurônios de saída e ocultos, respectivamente. Os resultados obtidos pelo modelo integrado foram comparados com resultados obtidos através de um planejamento fatorial e comprovaram a eficiência do método computacional proposto.

Neste trabalho, redes neurais foram empregadas para o estudo do processo de *filament winding*, sendo considerados dois casos: (a) predição de propriedades mecânicas e térmicas de peças, sendo os dados de treinamento obtidos do processo da empresa Polyplaster e (b) predição da variação de temperatura no interior de peças durante a etapa

de cura, sendo que os dados de treinamento foram obtidos através de um *software* baseado no modelo Lee-Springer.

4.1: Modelo Lee-Springer

A Figura 14 ilustra o sistema adotado no modelo Lee-Springer (LEE e SPRINGER, 1990a). Nesse modelo, considerou-se que a matriz é um polímero termofixo e que as fibras podem estar na forma de *prepreg* (*prepreg filament winding*) ou não (*wet filament winding*). As propriedades dos materiais em cada camada são constantes, mas podem variar de camada para camada.

Considerou-se que o mandril é um cilindro oco com espessura de parede uniforme. O compósito e o mandril apresentam comprimentos L iguais.




Figura 14: Descrição do Problema Estudado: L = comprimento, ϕ_0 = ângulo de enrolamento, r = coordenada radial, z = coordenada axial, V = velocidade de enrolamento, ω = velocidade angular do mandril (LEE e SPRINGER, 1990a).

O modelo Lee-Springer fornece, para um determinado conjunto de variáveis do processo como velocidade de enrolamento (V), tensão na fibra (F_0) e temperaturas aplicadas nas superfícies do mandril (T_m) e do compósito (T_c), parâmetros que caracterizam o compósito e mandril, em função do tempo, durante as etapas de enrolamento e cura. Para tanto, o modelo foi subdividido em cinco submodelos, os quais devem ser resolvidos simultaneamente. Nesse trabalho, foi considerado, no caso (b), apenas o submodelo

termoquímico, que fornece informações sobre a variação de temperatura no interior das peças. Esse submodelo é descrito a seguir.

4.1.1: Submodelo Termoquímico

O submodelo termoquímico fornece temperatura (T), grau de cura (α_c) e viscosidade (μ). Esse submodelo é similar ao proposto por CALIUS e SPRINGER (1990) para cilindros finos, porém ele considera transferência de calor nas direções radial e axial. A Figura 15 ilustra o sistema estudado, e a equação da conservação de energia para esse sistema é dada pela Equação 25 mostrada a seguir.




Figura 15: Sistema Estudado no Submodelo Termoquímico: T_m = temperatura na superfície do mandril, T_c = temperatura na superfície externa do compósito, h = espessura da peça, h_m = espessura do mandril (LEE e SPRINGER, 1990a).

$$\rho C \frac{\partial T}{\partial t} = \frac{1}{r} \frac{\partial}{\partial r} \left(K_r r \frac{\partial T}{\partial r} \right) + \frac{\partial}{\partial z} \left(K_z \frac{\partial T}{\partial z} \right) + \rho \dot{Q} \quad (25)$$

Sendo: T = temperatura no interior do compósito e do mandril

t = tempo

r = coordenada radial

z = coordenada axial

ρ = densidade

K_r = condutividade térmica na direção radial

K_z = condutividade térmica na direção axial

C = calor específico do compósito ou do mandril

\dot{Q} = taxa de geração de calor

A taxa de geração de calor é dada pela Equação 26. Assumindo que não está acontecendo nenhuma reação química na fibra, o último termo dessa equação é zero.

$$\rho \dot{Q} = \rho_r v_r \dot{Q}_r + \rho_f v_f \dot{Q}_f \quad (26)$$

Sendo: ρ_r = densidade da resina

ρ_f = densidade da fibra

v_r = fração de volume de resina

v_f = fração de volume de fibra

O grau de cura (α_c) é definido pela Equação 27:

$$\alpha_c = Q_r / H_u \quad (27)$$

Sendo: Q_r = calor do tempo $t = 0$ ao tempo t

H_u = calor total da reação

A partir da Equação 27, é possível obter uma expressão para \dot{Q}_r (Equação 28).

$$\dot{Q}_r = \left(\frac{d\alpha_c}{dt} \right) H_u \quad (28)$$

Substituindo-se as Equações 26 e 28 na Equação 25, obtém-se a Equação 29:

$$\rho C \frac{\partial T}{\partial t} = \frac{1}{r} \frac{\partial}{\partial r} \left(K_r r \frac{\partial T}{\partial r} \right) + \frac{\partial}{\partial z} \left(K_z \frac{\partial T}{\partial z} \right) + \rho_r v_r H_u \frac{d\alpha_c}{dt} \quad (29)$$

As propriedades do compósito podem variar com o grau de cura. Assume-se que o compósito é caracterizado por dois conjuntos de propriedades: um conjunto de valores quando o grau de cura é menor que um determinado valor α_1 ($\alpha < \alpha_1$) e outro quando o grau de cura é maior que α_2 ($\alpha > \alpha_2$). Entre α_1 e α_2 , assume-se que as propriedades variam linearmente com o grau de cura. A densidade (ρ), a condutividade térmica (K) e o calor específico (C) podem variar através Equações 30 a 32, onde os subscritos *cur* e *uncur* referem-se ao material curado ($\alpha=1$) e não curado ($\alpha=0$).

$$\rho = \alpha \rho_{cur} + (1 - \alpha) \rho_{uncur} \quad (30)$$

$$K = \alpha K_{cur} + (1 - \alpha) K_{uncur} \quad (31)$$

$$C = \alpha C_{cur} + (1 - \alpha) C_{uncur} \quad (32)$$

A variação do grau de cura com o tempo mostrada na Equação 29 pode ser expressa na forma mostrada em (33), onde $k^*(T)$ é a constante da taxa dada pela equação tipo Arrhenius (Equação 34), T é a temperatura de cura e $f(\alpha_c)$ é uma função que depende do modelo cinético adotado para a cura da resina.

$$\frac{d\alpha_c}{dt} = k^*(T)f(\alpha_c) \quad (33)$$

$$k^*(T) = A \exp\left(-\frac{E_a}{RT}\right) \quad (34)$$

Sendo: A = fator pré-exponencial

E_a = energia de ativação

R = constante dos gases

Os modelos cinéticos mais usuais são o modelo de ordem n e o modelo autocatalítico, conforme mostram as Equações 35 e 36, respectivamente (CALADO e ADVANI, 1999).

$$\text{Modelo Cinético de Cura de Ordem } n: f(\alpha) = (1 - \alpha)^n \quad (35)$$

$$\text{Modelo Cinético de Cura Autocatalítico: } f(\alpha) = (1 - k_2' \alpha^m)(1 - \alpha)^n \quad (36)$$

As condições iniciais (temperatura e grau de cura em $t = t_0$) são: $T = T_0$ e $\alpha_c = \alpha_{c0}$. Uma vez que a espessura da peça é construída gradualmente, t_0 é diferente para cada camada.

As condições de contorno são:

$$T = T_C \text{ em } r = R_{mo} + h, \quad 0 \leq z \leq L \quad (37)$$

$$T = T_m \text{ em } r = R_{mi}, \quad 0 \leq z \leq L \quad (38)$$

$$T = T_L \text{ em } z = 0, \quad R_{mi} \leq r \leq R_{mo} + h \quad (39)$$

$$T = T_R \text{ em } z = L, \quad R_{mi} \leq r \leq R_{mo} + h \quad (40)$$

Sendo: T_C = temperatura na superfície externa do cilindro compósito

T_m = temperatura na superfície externa do mandril

T_R = temperatura na extremidade direita

T_L = temperatura na extremidade esquerda

R_{mi} = raio interno do mandril

R_{mo} = raio externo do mandril

h = espessura (varia com o tempo)

Uma vez conhecidas a temperatura e o grau de cura, a viscosidade pode ser obtida através de uma expressão do tipo mostrado em (41), sendo que para cada resina existe uma determinada correlação. Detalhes sobre os modelos clássicos de viscosidade podem ser encontrados em (CALADO e ADVANI, 1999).

$$\mu = f(\alpha_c, T) \quad (41)$$

CAPÍTULO 5: DADOS UTILIZADOS NO TREINAMENTO DAS REDES

5.1: Caso (a) - Dados da Empresa Polyplaster

Os dados do processo da Polyplaster referem-se ao sistema resina éster vinílico/fibra de vidro com as características apresentadas na Tabela 7. A fibra de vidro utilizada pertence ao tipo E, que constitui um dos tipos de fibra de vidro mais empregados na fabricação de peças de material compósito.

Tabela 7: Características dos Materiais Utilizados nas Peças da Polyplaster.

Propriedade	Fibra	Resina
Densidade (g/cm^3)	2,600	1,130
Módulo de Elasticidade (GPa)	73	2,95
Coefficiente de Dilatação Térmica (10^{-6} cm^{-1})	5	65
Razão de Poisson	0,2	0,35

Foram considerados tubos contendo quatro camadas conforme ilustrado na Figura 16. A camada mais interna dos tubos (*liner*) é um revestimento feito de resina que possibilita alta resistência à corrosão. As camadas dois (estrutura-casca interna) e três (núcleo intermediário) empregaram fibras cortadas e visam o aumento da rigidez da peça. A última camada (estrutura-casca externa) foi produzida através do método de *filament winding* empregando padrões de enrolamento da fibra circunferenciais (ângulo de enrolamento de 90° , como ilustra a Figura 13 do capítulo 3). As camadas apresentaram diferentes teores de fibra: a primeira camada foi produzida somente com resina, a camada dois apresentou um teor de fibra de vidro de 60% em peso para todas as peças, a camada três apresentou teores de fibra variando entre 23 e 48% e a camada mais externa apresentou sempre 80% de fibra de vidro.

O diâmetro nominal dos tubos variou de 300 a 2500mm, com espessuras entre 5,5 e 31,7mm e pesos entre 9,9 e 213,4kg/m.




Figura 16: Tubo Polyplaster.

As principais propriedades mecânicas dos tubos foram determinadas através de ensaios de caracterização experimental, bem como o coeficiente de dilatação térmica (propriedade térmica) e, conforme será mostrado adiante, serão utilizadas no treinamento das redes. Na indústria, esses ensaios têm dois objetivos principais: obter dados preliminares de propriedades para fins de comparação e/ou controle de qualidade, e gerar dados detalhados de projeto. Conforme enfatizado em ADAMS (2000), os testes mecânicos podem ser muito demorados e também muito caros.

Do ponto de vista mecânico, os compósitos fibrosos pertencem à classe dos materiais denominados ortotrópicos, que são aqueles cujo comportamento está entre o dos materiais isotrópicos e anisotrópicos. A diferença entre esses dois materiais pode ser melhor explicada através de suas respostas a cargas de tração e cisalhamento, como ilustra a Figura 17 para um corpo retangular.

Conforme mostra a Figura 17, uma tensão uniaxial aplicada a um corpo isotrópico irá produzir uma elongação na direção da carga e um encurtamento na direção perpendicular a ela, sem mudança nos ângulos entre dois lados adjacentes. Uma carga cisalhante irá provocar distorção no corpo através de mudanças nos ângulos entre dois lados adjacentes, sem alterar o comprimento. Portanto, o comportamento de deformação dos materiais isotrópicos é independente da direção, uma vez que cargas iguais aplicadas em diferentes direções produzem mudanças iguais nos comprimentos e ângulos.

A Figura 17 mostra que tanto a tensão uniaxial quanto o cisalhamento aplicados em um material anisotrópico provocam mudanças nos comprimentos e também nos ângulos. Logo, o comportamento de deformação dessa classe de materiais é dependente da direção, uma vez que cargas iguais aplicadas em direções diferentes geram mudanças diferentes nos comprimentos e ângulos.




Figura 17: Comportamento de Deformação dos Materiais Isotrópicos e Anisotrópicos (AGARWAL e BROUTMAN, 1990).

O comportamento de deformação dos materiais ortotrópicos é em geral similar ao exibido pelos materiais anisotrópicos. No entanto, em alguns casos especiais, quando a carga é aplicada em direções específicas (eixos de simetria do material), a sua resposta assemelha-se à dos materiais isotrópicos. A existência dos eixos de simetria e a quantidade deles são governadas pela microestrutura do material, sendo que um material ortotrópico típico tem três eixos de simetria mutuamente perpendiculares (x , y , z ou 1,2,3). Um compósito unidirecional tem mais do que três eixos de simetria: a direção longitudinal, isto é, a direção da fibra, e todas as direções perpendiculares a ela. Devido a esses eixos adicionais de simetria, os compósitos unidirecionais são considerados transversalmente isotrópicos (AGARWAL e BROUTMAN, 1990).

As duas direções de principal interesse são as direções 1, isto é, direção longitudinal, e 2, isto é, direção transversa (ADAMS, 2000). Neste trabalho, foram consideradas propriedades medidas nessas direções.

As principais propriedades mecânicas dos materiais são as constantes elásticas e as resistências. Para os compósitos, existem quatro constantes elásticas (módulo de elasticidade na direção axial, módulo de elasticidade na direção transversa, módulo de cisalhamento e maior razão de Poisson) e cinco resistências (resistência à tração na direção axial, resistência à tração na direção transversa, resistência à compressão na direção axial, resistência à compressão na direção transversa e resistência ao cisalhamento no plano). Além dessas, outras propriedades importantes são a resistência ao cisalhamento interlaminar, o coeficiente de expansão térmica e as propriedades de flexão.

O módulo de elasticidade, a resistência à tração e a razão de Poisson podem ser determinadas através de testes de tensão uniaxial, onde são medidas a carga aplicada e as deformações ocorridas. A inclinação inicial da curva tensão-deformação para carga aplicada na direção longitudinal fornece o módulo de elasticidade na direção longitudinal, e para carga aplicada na direção transversa, o módulo transverso. As resistências à tração (longitudinal e transversa) são obtidas conhecendo-se a carga que provocou a fratura.

A razão de Poisson deve ser determinada quando se deseja caracterizar completamente o material. A razão ou coeficiente de Poisson representa a razão entre a deformação induzida na direção lateral com a deformação na direção da carga normal, a qual pode ser de tração ou compressão. Normalmente, o valor da razão de Poisson não varia significativamente entre as cargas de tração e compressão e portanto costuma-se não fazer distinção. Para cargas no plano, duas razões de Poisson são definidas: a maior razão de Poisson relaciona a carga longitudinal com a deformação transversa e a menor razão de Poisson relaciona a carga transversa com a deformação longitudinal.

Os testes de compressão são similares aos testes de tração, mas apresentam muitos problemas, sendo um dos principais a dificuldade para evitar a formação de saliências ou dobras nos corpos de prova (instabilidade elástica). Atualmente, os testes de compressão estática para materiais compósitos são considerados os tipos de teste mais controversos que existem (ADAMS, 2000).

O coeficiente de expansão térmica dos materiais pode ser obtido através de medições da dilatação de um corpo de prova com a variação da temperatura. Para os materiais compósitos, existem dois coeficientes principais: coeficiente de dilatação térmica na direção longitudinal e na direção transversa. Essas propriedades podem ser determinadas utilizando-se um corpo de prova retangular de dimensões 50mm x 50mm, aquecido a uma taxa de cerca de 1°C/min (a temperatura é monitorada com auxílio de um termopar). Uma vez que a umidade induz mudanças dimensionais em muitas resinas, é importante secar os corpos de prova antes dos ensaios (AGARWAL e BROUTMAN, 1990).

As Tabelas 8(a) e (b) mostram os dados da planta da empresa Polyplaster.

Tabela 8(a): Dados Polyplaster.

Dado	Composição Global (% em peso)			DN (mm)	h (mm)	M _{tubo} (kg/m)	ax (10 ⁻⁵) m/°C.m)	ay (10 ⁻⁵) m/°C.m)
	Resina	Fibra Cortada	Fibra Contínua					
1	48	30	22	300	6,4	9,86	2,13	2,73
2	51	35	14	300	12,5	19,18	2,2	2,57
3	51	35	14	300	11,6	17,75	2,18	2,55
4	55	35	10	400	26	52,74	2,34	2,59
5	51	35	14	400	9,2	18,49	2,2	2,57
6	51	35	14	400	15,3	31,20	2,17	2,54
7	48	30	22	400	8	16,41	2,11	2,7
8	48	27	25	500	8,75	22,38	2,18	2,85
9	51	35	14	500	19	48,42	2,16	2,53
10	51	35	14	500	17,5	44,47	2,19	2,56
11	48	30	22	500	9,5	24,34	2,09	2,69
12	48	30	22	600	11,1	34,11	2,08	2,68
13	45	25	30	600	9	28,24	2,04	2,87
14	51	35	14	600	13,6	40,98	2,18	2,55
15	52	37	11	600	31,7	97,57	2,2	2,49
16	45	25	30	700	10,5	38,44	2,05	2,88
17	50	25	25	700	20	71,27	2,18	2,84
18	60	35	5	700	12,7	41,52	2,54	2,66
19	51	35	14	700	15,8	55,53	2,17	2,54
20	48	25	27	800	12	49,00	2,16	2,89
21	53	30	17	800	20	79,29	2,27	2,71
22	53	30	17	800	10,5	41,14	2,29	2,73
23	48	20	32	800	12,5	51,07	2,16	3,03
24	51	35	14	1000	24,4	122,74	2,18	2,55
25	50	30	20	1000	8	39,91	2,19	2,72
26	48	27	25	1000	15	76,56	2,13	2,8
27	50	20	30	1000	12,5	62,64	2,36	3,16
28	45	25	30	1200	20	125,71	1,97	2,8
29	45	25	30	1200	28,8	182,33	1,95	2,78
30	45	25	30	1200	9	56,06	1,99	2,82
31	48	27	25	1200	18	110,24	2,11	2,79
32	50	30	20	2000	7,5	74,51	2,2	2,73
33	45	25	30	2000	20,5	213,40	1,98	2,81
34	54	25	21	2500	7,5	90,23	2,45	2,99
35	45	25	30	2500	6	77,47	2,03	2,86
36	55	25	20	1600	5,5	42,04	2,53	3,04
37	45	25	30	1600	10,5	87,12	2,05	2,88
38	45	25	30	1600	20,5	171,15	1,98	2,81

DN = Diâmetro nominal

ax = Coeficiente de dilatação térmica na direção circunferencial

ay = Coeficiente de dilatação térmica na direção axial

h = Espessura da peça

M_{tubo} = Peso do tubo

Tabela 8(b): Dados Polyplaster: Continuação da Tabela 8(a).

Dado	Ex (10 ¹⁰ Pa)	Ey (10 ⁹ Pa)	S (10 ⁹ Pa)	Ux	X (10 ⁸ Pa)	Y (10 ⁸ Pa)	Y' (10 ⁸ Pa)
1	1,66	9,12	3,7	0,30	2,83	0,64	1,19
2	1,37	9,05	3,71	0,31	2,33	0,63	1,18
3	1,37	9,05	3,71	0,31	2,33	0,63	1,18
4	1,18	8,56	3,52	0,31	2	0,60	1,11
5	1,37	9,05	3,71	0,31	2,33	0,63	1,18
6	1,37	9,05	3,71	0,31	2,33	0,63	1,18
7	1,66	9,12	3,7	0,30	2,83	0,64	1,19
8	1,74	8,93	3,61	0,30	2,97	0,62	1,16
9	1,37	9,05	3,71	0,31	2,33	0,63	1,18
10	1,37	9,05	3,71	0,31	2,33	0,63	1,18
11	1,66	9,12	3,7	0,30	2,83	0,64	1,19
12	1,66	9,12	3,7	0,30	2,83	0,64	1,19
13	1,97	9,19	3,69	0,30	3,34	0,64	1,2
14	1,37	9,05	3,71	0,31	2,33	0,63	1,18
15	1,27	9,05	3,72	0,31	2,16	0,63	1,18
16	1,97	9,19	3,69	0,30	3,34	0,64	1,2
17	1,69	8,54	3,45	0,30	2,88	0,60	1,11
18	0,95	7,98	3,3	0,32	1,62	0,56	1,04
19	1,37	9,05	3,71	0,31	2,33	0,63	1,18
20	1,8	8,8	3,54	0,30	3,06	0,62	1,14
21	1,41	8,49	3,46	0,31	2,39	0,59	1,1
22	1,41	8,49	3,46	0,31	2,39	0,59	1,1
23	1,94	8,47	3,38	0,30	3,29	0,59	1,1
24	1,37	9,05	3,71	0,31	2,33	0,63	1,18
25	1,56	8,86	3,6	0,30	2,65	0,62	1,15
26	1,74	8,93	3,61	0,30	2,97	0,62	1,16
27	1,83	8,22	3,29	0,30	3,11	0,58	1,07
28	1,97	9,19	3,69	0,30	3,34	0,64	1,2
29	1,97	9,19	3,69	0,30	3,34	0,64	1,2
30	1,97	9,19	3,69	0,30	3,34	0,64	1,2
31	1,74	8,93	3,61	0,30	2,97	0,62	1,16
32	1,56	8,86	3,6	0,30	2,65	0,62	1,15
33	1,97	9,19	3,69	0,30	3,34	0,64	1,2
34	1,49	8,05	3,27	0,31	2,53	0,56	1,05
35	1,97	9,19	3,69	0,30	3,34	0,64	1,2
36	1,44	7,94	3,22	0,31	2,45	0,56	1,03
37	1,97	9,19	3,69	0,30	3,34	0,64	1,2
38	1,97	9,19	3,69	0,30	3,34	0,64	1,2

Ex = Módulo de elasticidade na tração circunferencial

X = Tensão de tração circunferencial (na ruptura)

Ey = Módulo de elasticidade na tração axial

S = Módulo de cisalhamento (no plano)

Ux = Maior razão de Poisson

Y = Tensão de tração axial

Y' = Tensão de compressão axial

5.2: Caso (b) - Dados do Modelo Lee-Springer

Neste caso, redes neurais foram utilizadas para predição de temperatura no interior de cilindros, durante a etapa de cura. Para geração dos dados, foi utilizado o *software* Windthick da Universidade de Stanford que é baseado no modelo Lee-Springer.

Foram considerados dois tipos de resina epóxi (Fiberite 976 e HBRF55) e dois tipos de fibra (grafite Thornel T-300 e fibra de vidro tipo S), cujas propriedades são mostradas nas Tabelas 9 e 10, respectivamente.

Tabela 9: Propriedades das Resinas Epóxi (^aTANG *et alii*, 1987, ^bZHAO *et alii*, 2001).

Propriedade	Fiberite 976 ^a	HBRF55 ^b
Densidade (kg/m ³)	1260	1261,6
Calor específico (kJ/kg.K)	1,26	1,34
Condutividade térmica (J/s.m.K)	0,167	0,25

Tabela 10: Propriedades das Fibras (^aTANG *et alii*, 1987, ^bCHAMIS, 1984)

Propriedade	Grafite T-300 ^a	S-Glass ^b
Densidade (kg/m ³)	1790	2491
Calor específico (kJ/kg.K)	0,712	0,712
Condutividade térmica transversa (J/s.m.K)	26,0	3,03
Condutividade térmica longitudinal (J/s.m.K)	8,5	3,03

Foram considerados 21 cilindros contendo teores de fibra entre 50 e 70% e espessuras entre 0,15 e 1,2 in, aos quais foram aplicados diferentes ciclos de cura (temperaturas de cura, taxas de aquecimento e resfriamento, e tempo). A Tabela 11 mostra as temperaturas em diferentes posições no interior desses cilindros, que foram utilizadas no treinamento das redes neurais.

Para todas as peças, assumiu-se padrão de enrolamento de fibra helicoidal (ângulo de enrolamento $\pm 55^\circ$), velocidade angular do mandril 3,14 rad/s, diâmetro interno 2 in e comprimento 18 in. Considerou-se um mandril de alumínio com as propriedades mostradas em CALIUS *et alii* (1990).

Tabela 11: Características das Peças (resina 1 = 976, fibra 1 = T-300, resina 2 = HBRF55, fibra 2 = vidro S).

Resina	Fibra	Teor de Fibra (% em volume)	Espessura da Peça (in)	t (h)	T na superfície (°F)	Altura da medição (in)	T no interior (°F)
1	1	59	1,00	6,0	350,0	0,50	350,0
1	1	59	1,00	10,0	75,0	0,50	78,8
1	1	59	1,00	1,0	143,8	0,25	140,8
1	1	59	1,00	2,0	212,5	0,25	209,9
1	1	59	1,00	3,0	281,3	0,25	282,5
1	1	59	1,00	4,0	350,0	0,25	354,2
1	1	59	1,00	5,0	350,0	0,25	350,2
1	1	59	1,00	6,0	350,0	0,25	350,0
1	1	59	1,00	7,0	281,3	0,25	284,2
1	1	59	1,00	9,0	143,8	0,25	146,7
1	1	59	1,00	10,0	75,0	0,25	78,0
1	1	59	1,00	1,0	143,8	0,75	141,1
1	1	59	1,00	2,0	212,5	0,75	210,1
1	1	59	1,00	3,0	281,3	0,75	282,4
1	1	59	1,00	4,0	350,0	0,75	353,9
1	1	59	1,00	5,0	350,0	0,75	350,1
1	1	59	1,00	6,0	350,0	0,75	350,0
1	1	59	1,00	7,0	281,3	0,75	284,0
1	1	59	1,00	8,0	212,5	0,75	215,2
1	1	59	1,00	9,0	143,8	0,75	146,5
1	1	59	1,00	10,0	75,0	0,75	77,7
1	1	59	1,20	4,0	300,0	0,60	314,3
1	1	59	1,20	10,0	65,0	0,60	69,6
1	1	59	0,50	5,0	400,0	0,25	400,0
1	1	59	0,50	6,0	400,0	0,25	400,0
1	1	59	0,50	10,0	82,0	0,25	83,1
1	1	59	0,80	3,0	280,0	0,40	281,1
1	1	59	0,80	10,0	80,0	0,40	82,3
1	1	50	1,00	4,0	350,0	0,50	354,9
1	1	50	1,00	10,0	75,0	0,50	79,9
1	1	70	1,20	4,0	300,0	0,60	305,5
1	1	70	1,20	6,0	300,0	0,60	300,6
1	2	59	1,00	2,0	350,0	0,50	384,8
1	2	59	1,00	3,0	350,0	0,50	350,4
1	2	59	0,20	3,0	300,0	0,10	300,0
1	2	59	0,20	5,0	65,0	0,10	65,4
1	2	59	0,50	2,0	400,0	0,25	401,3
1	2	59	0,50	5,0	82,0	0,25	85,0
1	2	59	0,80	1,0	213,3	0,40	207,2
1	2	59	0,80	2,0	280,0	0,40	285,4
1	2	59	0,80	5,0	80,0	0,40	86,4
1	2	50	1,00	2,0	350,0	0,50	429,7
1	2	50	1,00	3,0	350,0	0,50	350,3
1	2	50	1,00	5,0	75,0	0,50	87,8
1	2	70	1,20	2,0	300,0	0,60	295,7
1	2	70	1,20	3,0	300,0	0,60	308,2
1	2	70	1,20	5,0	65,0	0,60	74,4
1	2	70	0,50	2,0	300,0	0,25	300,0
1	2	70	0,50	3,0	300,0	0,25	301,0
1	2	70	0,50	5,0	65,0	0,25	67,0
1	1	55	0,15	2,0	320,0	0,08	320,3
1	2	70	0,15	4,0	320,0	0,08	320,0
1	1	55	0,15	6,0	90,0	0,08	90,2

Tabela 11: Continuação (resina 1 = 976, fibra 1 = T-300, resina 2 = HBRF55, fibra 2 = vidro S).

Resina	Fibra	Teor de Fibra (% em volume)	Espessura da Peça (in)	t (h)	T na superfície (°F)	Altura da medição (in)	T no interior (°F)
1	1	65	0,25	2,0	320,0	0,13	320,4
1	1	65	0,25	4,0	320,0	0,13	320,0
1	1	65	0,25	6,0	90,0	0,13	90,3
2	1	59	0,50	4,0	350,0	0,25	349,3
2	1	59	0,50	6,0	350,0	0,25	350,0
2	1	59	0,50	10,0	75,0	0,25	75,7
1	1	59	1,20	4,0	300,0	0,30	311,3
1	1	59	1,20	6,0	300,0	0,30	300,8
1	1	59	1,20	10,0	65,0	0,30	68,7
1	1	59	0,50	4,0	400,0	0,38	399,3
1	1	59	0,50	6,0	400,0	0,38	400,0
1	1	59	0,50	10,0	82,0	0,38	82,8
1	1	59	0,80	5,0	280,0	0,20	281,7
1	1	59	0,80	7,0	280,0	0,20	280,2
1	1	59	0,80	9,0	146,8	0,20	148,5
1	1	59	0,80	3,0	280,0	0,60	280,8
1	1	59	0,80	7,0	280,0	0,60	280,2
1	1	59	0,80	8,0	213,4	0,60	215,0
1	1	50	1,00	2,0	212,5	0,25	209,2
1	1	50	1,00	7,0	281,3	0,25	285,1
1	1	50	1,00	8,0	212,5	0,25	216,4
1	1	70	1,20	4,0	300,0	0,90	303,9
1	1	70	1,20	6,0	300,0	0,90	300,5
1	1	70	1,20	10,0	65,0	0,90	67,2
1	2	59	1,00	1,0	212,5	0,25	204,6
1	2	59	1,00	3,0	350,0	0,25	350,3
1	2	59	1,00	5,0	75,0	0,25	83,2
1	2	59	1,00	1,0	212,5	0,75	205,3
1	2	59	1,00	3,0	350,0	0,75	350,3
1	2	59	1,00	5,0	75,0	0,75	82,5
1	2	59	0,20	2,0	300,0	0,15	300,0
1	2	59	0,20	3,0	300,0	0,15	300,3
1	2	59	0,20	5,0	65,0	0,15	65,3
1	2	59	0,50	2,0	400,0	0,38	400,9
1	2	59	0,50	3,0	400,0	0,38	400,0
1	2	59	0,50	5,0	82,0	0,38	84,2
1	2	59	0,80	2,0	280,0	0,20	284,2
1	2	59	0,80	3,0	280,0	0,20	284,1
1	2	59	0,80	5,0	80,0	0,20	85,0
1	2	59	0,80	3,0	280,0	0,60	283,8
1	2	59	0,80	5,0	80,0	0,60	84,7
1	2	50	1,00	3,0	350,0	0,25	350,2
1	2	50	1,00	5,0	75,0	0,25	85,1
1	2	70	1,20	2,0	300,0	0,30	296,6
1	2	70	1,20	5,0	65,0	0,30	72,5
1	2	70	1,20	2,0	300,0	0,90	297,0
1	2	70	1,20	3,0	300,0	0,90	305,9
1	2	70	1,20	5,0	65,0	0,90	71,8
1	2	70	0,50	2,0	300,0	0,12	299,7
1	2	70	0,50	3,0	300,0	0,12	301,0
1	2	70	0,50	5,0	65,0	0,12	62,2
1	1	55	0,15	1,0	205,0	0,04	204,9

Tabela 11: Continuação (resina 1 = 976, fibra 1 = T-300, resina 2 = HBRF55, fibra 2 = vidro S).

Resina	Fibra	Teor de Fibra (% em volume)	Espessura da Peça (in)	t (h)	T na superfície (°F)	Altura da medição (in)	T no interior (°F)
1	1	55	0,15	2,0	320,0	0,04	320,2
1	1	55	0,15	1,0	205,0	0,11	204,9
1	1	55	0,15	4,0	320,0	0,11	320,0
1	1	55	0,15	6,0	90,0	0,11	90,1
1	1	65	0,25	2,0	320,0	0,19	320,3
1	1	65	0,25	4,0	320,0	0,19	320,0
1	1	65	0,25	6,0	90,0	0,19	90,2
2	1	59	0,50	4,0	350,0	0,12	349,5
2	1	59	0,50	6,0	350,0	0,12	350,0
2	1	59	0,50	10,0	75,0	0,12	75,5
2	1	59	0,50	4,0	350,0	0,37	349,5
2	1	59	0,50	8,0	212,5	0,37	213,0
2	1	59	0,50	9,0	143,8	0,37	144,2
2	1	59	0,50	10,0	75,0	0,37	75,5
2	1	50	0,28	1,0	138,0	0,14	140,0
2	2	65	0,30	1,0	152,5	0,15	153,9
2	2	65	0,30	2,0	240,0	0,15	239,6
2	2	65	0,30	3,0	242,5	0,15	242,5
2	2	65	0,30	4,0	245,0	0,15	245,0
2	2	65	0,30	2,0	240,0	0,21	239,7
2	2	65	0,30	4,0	245,0	0,21	245,0
2	2	65	0,30	6,0	65,0	0,21	65,3
2	2	54	0,53	1,0	152,5	0,26	159,0
2	2	54	0,53	2,0	240,0	0,26	238,5
2	2	54	0,53	3,0	242,5	0,26	242,5
2	2	54	0,53	4,0	245,0	0,26	245,0
2	2	54	0,53	5,0	155,0	0,26	156,6
2	2	54	0,53	4,0	245,0	0,13	245,0
2	2	54	0,53	6,0	65,0	0,13	66,2
2	1	63	0,32	4,0	350,0	0,08	349,7
2	1	63	0,32	6,0	350,0	0,08	350,0
2	1	63	0,32	10,0	75,0	0,08	75,3
2	1	63	0,32	4,0	350,0	0,16	349,7
2	1	63	0,32	6,0	350,0	0,16	350,0
2	1	63	0,32	10,0	75,0	0,16	75,3
2	1	63	0,32	4,0	350,0	0,24	349,8
2	1	63	0,32	6,0	350,0	0,24	350,0
2	1	63	0,32	10,0	75,0	0,24	75,3
1	1	50	0,32	1,0	143,8	0,08	143,4
1	1	50	0,32	2,0	212,5	0,08	212,2
1	1	50	0,32	5,0	350,0	0,08	350,0
1	1	50	0,32	10,0	75,0	0,08	75,4
1	1	50	0,32	4,0	350,0	0,16	351,3
1	1	50	0,32	5,0	350,0	0,24	350,0
1	1	50	0,32	8,0	212,5	0,24	212,9
1	1	59	1,00	4,0	350,0	0,50	355,2
1	1	59	1,00	8,0	212,5	0,25	215,5
1	1	59	1,20	6,0	300,0	0,60	300,9
1	1	59	0,50	4,0	400,0	0,25	399,1
1	1	59	0,80	7,0	280,0	0,40	280,3
1	1	50	1,00	6,0	350,0	0,50	350,0
1	1	70	1,20	10,0	65,0	0,60	68,1
1	2	59	1,00	5,0	75,0	0,50	85,4

Tabela 11: Continuação (resina 1 = 976, fibra 1 = T-300, resina 2 = HBRF55, fibra 2 = vidro S).

Resina	Fibra	Teor de Fibra (% em volume)	Espessura da Peça (in)	t (h)	T na superfície (°F)	Altura da medição (in)	T no interior (°F)
1	2	59	0,20	2,0	300,0	0,10	300,0
1	2	59	0,50	3,0	400,0	0,25	400,0
1	2	59	0,80	2,0	280,0	0,60	283,9
1	2	50	1,00	2,0	350,0	0,25	411,3
1	2	70	1,20	3,0	300,0	0,30	306,5
1	1	55	0,15	3,0	320,0	0,04	320,1
2	1	59	0,50	6,0	350,0	0,37	350,0
2	1	59	0,50	7,0	281,3	0,37	281,7
2	2	65	0,30	5,0	155,0	0,15	155,4
2	2	65	0,30	6,0	65,0	0,15	65,4
2	2	54	0,53	6,0	65,0	0,26	66,6
2	2	54	0,53	2,0	240,0	0,13	238,8
2	2	63	0,32	6,0	350,0	0,16	350,0
2	2	63	0,32	10,0	75,0	0,16	75,5
2	2	63	0,32	3,0	281,3	0,24	281,6
2	2	63	0,32	9,0	143,8	0,24	144,1

CAPÍTULO 6: METODOLOGIA PARA TREINAMENTO DAS REDES

6.1: Caso (a) - Predição de Propriedades Finais

Foram considerados dois tipos de redes neurais para o caso (a): rede para predição de propriedade mecânica, ou seja, da resposta do material compósito à aplicação de uma carga mecânica e rede para predição do coeficiente de dilatação térmica, propriedade térmica que avalia a mudança nas dimensões do material submetido a mudanças na temperatura.

Os exemplos utilizados nas redes neurais foram mostrados na Tabela 8 no capítulo anterior. Daqueles dados, foi retirado aleatoriamente um conjunto para teste, tomando-se o cuidado para os exemplos estarem dentro da faixa abrangida pelo conjunto de treinamento, uma vez que a rede não se mostra suficientemente confiável quando trabalha com dados que estejam fora do espaço do conjunto *input-output* de aprendizado.

Para as redes de propriedade mecânica, foram utilizados três neurônios na camada *input*, representando a composição do global do sistema, e um neurônio na camada *output* para cada rede, correspondendo a um resultado de ensaio mecânico. Foram utilizados 10 exemplos de treinamento e 5 para teste. Para essa rede, ilustrada na Figura 18, tem-se os *inputs* e *outputs* mostrados a seguir.

Neurônios na Camada *Input*:

- Teor de resina
 - Teor de fibra cortada
 - Teor de fibra contínua
-

Neurônios na Camada *Output*:

- Módulo de elasticidade na tração circunferencial
- Módulo de elasticidade na tração axial
- Módulo de cisalhamento (no plano)
- Maior razão de Poisson
- Tensão de tração circunferencial (na ruptura)
- Tensão de tração axial
- Tensão de compressão axial

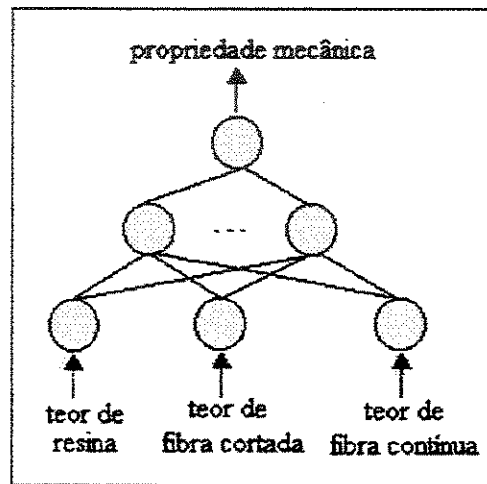


Figura 18: Rede Neural para Predição de Propriedade Mecânica.

Para o treinamento da rede de coeficiente de dilatação térmica, foram utilizados seis neurônios na camada *input*, representando composição e geometria (uma vez que esse fator influencia essa propriedade) das peças, e um neurônio na camada *output* para cada rede, representando o coeficiente de dilatação na direção circunferencial ou axial. Foram utilizados 28 exemplos para o treinamento e 10 para a fase de teste. Para essa rede, ilustrada na Figura 19, tem-se os neurônios mostrados a seguir.

Neurônios na Camada *Input*:

- Teor global de resina
- Teor global de fibra cortada
- Teor global de fibra contínua
- Diâmetro do tubo
- Espessura do tubo
- Peso do tubo

Neurônios na Camada *Output*:

- Coeficiente de dilatação térmica na direção circunferencial
- Coeficiente de dilatação térmica na direção axial




Figura 19: Rede Neural para Predição de Propriedade Térmica.

6.2: Caso (b) - Predição de Temperatura

A rede para predição da temperatura no interior dos cilindros que obedecem ao modelo Lee-Springer, ilustrada na Figura 20, contou com os neurônios mostrados a seguir. Os dados utilizados no treinamento das redes foram mostrados na Tabela 11 do capítulo 5. Foram considerados 150 exemplos de treinamento e 24 exemplos de teste.




Figura 20: Rede Neural para Predição do Comportamento Térmico de Peças.

Neurônios na Camada *Input*:

- Densidade da camada compósita
- Condutividade da camada compósita
- Calor específico da camada compósita
- Espessura da peça
- Temperatura na superfície da peça
- Altura da medição
- Tempo

Neurônio na Camada *Output*:

- Temperatura no interior da peça

Para cálculo das propriedades do compósito, foram utilizadas, conforme sugerido em CALIUS *et alii* (1990), as expressões propostas em CHAMIS (1984). Para cálculo da densidade (ρ_c), calor específico (C_c) e condutividade térmica transversa (K_{c22}) da camada compósita, utilizaram-se as Equações 42, 43 e 44, respectivamente.

$$\rho_c = v_f \rho_f + v_r \rho_r \quad (42)$$

$$C_c = \frac{1}{\rho_c} (v_f \rho_f C_f + v_r \rho_r C_r) \quad (43)$$

$$K_{c22} = K_{c33} = (1 - \sqrt{v_f}) K_r + \frac{K_r \sqrt{v_f}}{1 - \sqrt{v_f} (1 - K_r / K_{f22})} \quad (44)$$

Sendo: ρ_r = densidade da resina

ρ_f = densidade da fibra

v_f = fração de volume de fibra

v_r = fração de volume de resina

C_r = calor específico da resina

C_f = calor específico da fibra

K_r = condutividade térmica da resina

K_{f22} = condutividade térmica transversa da fibra

Após o treinamento das redes, o aprendizado foi validado com dados experimentais reportados em CALIUS *et alii* (1990), para quatro cilindros cujas características são mostradas na Tabela 12.

Tabela 12: Características dos Cilindros Reportados em CALIUS *et alii* (1990).

Cilindro	Espessura (in)	Diâmetro Interno (in)	Ângulo de Enrolamento	Comprimento (in)	Tempo de Cura (h)
A	0,156	6	$\pm 55^\circ$	25	10
B	0,25	3	$\pm 55^\circ$	18	10
C	1,0	3	$\pm 43^\circ$	20	10
D	0,27	3	$\pm 40^\circ$	18	14

6.3: Desenvolvimento do Programa Computacional

Neste item, será apresentado o programa computacional que foi desenvolvido em linguagem Fortran[®] para treinamento e teste das redes neurais. O programa foi baseado no algoritmo de *backpropagation*, considerando como função de transferência para todos os neurônios da rede a função sigmoideal, e adotando polarizações (*bias*) para as camadas *hidden* e *output*.

É interessante observar que estão disponíveis no mercado *softwares* específicos para redes neurais, como por exemplo QwikNet[®] (produzido pela Craig Jensen) e NeuroSolutions[®] (produzido pela NeuroDimension), que, por apresentarem uma interface simplificada, podem ser utilizados satisfatoriamente mesmo por pessoas menos familiarizadas com as teorias de redes. No entanto, um dos problemas para o usuário desses simuladores comerciais é que ele não tem acesso a todas as rotinas de cálculo e, dessa forma, não tem total conhecimento de como os programas são conduzidos, e portanto não tem total controle sobre o treinamento da rede. Além disso, os *softwares* não permitem que seus algoritmos internos sejam alterados para melhor se adaptarem ao caso em estudo de forma a obter a melhor performance.

A literatura mostra que muitos dos problemas estudados com o auxílio de redes neurais têm sido resolvidos utilizando apenas uma, e algumas vezes, duas camadas ocultas (KONDERLA e MOKANEK, 2000, SWINGLER, 1996). Neste trabalho, utilizaram-se redes contendo uma única camada *hidden*.

Uma apresentação completa do conjunto de treinamento inteiro é chamada de iteração ou época. O aprendizado em redes neurais é decorrência de muitas iterações, que

são realizadas até a estabilização dos pesos sinápticos e das polarizações (*bias*), e da convergência do erro médio para um valor mínimo. Para um dado conjunto de treinamento, a aprendizagem por retropropagação pode proceder de uma entre duas formas básicas: modo *on-line* ou modo batelada (HAYKIN, 2001).

O modo *on-line* também é chamado de modo seqüencial, padrão, padrão-a-padrão ou estocástico. Nesse modo de operação, a atualização dos pesos é realizada após a apresentação de cada exemplo de treinamento. Mais especificamente, considere uma iteração consistindo de n exemplos (vetores) de treinamento arranjados na ordem $(\bar{x}(1), \bar{y}(1)), \dots, (\bar{x}(n), \bar{y}(n))$. O primeiro par de exemplos $(\bar{x}(1), \bar{y}(1))$ da iteração é apresentado à rede, e a seqüência de computações *forward* e *backward* é realizada, resultando em ajustes dos pesos e *bias*. Em seguida, o segundo par de exemplos da iteração é apresentado. Esse processo se repete até que o último par de exemplos $(\bar{x}(n), \bar{y}(n))$ seja considerado.

No modo batelada ou por lote, o ajuste dos pesos é realizado após a apresentação de todos os exemplos de treinamento que constituem uma época.

O modo *on-line* de treinamento é preferível em relação ao modo batelada porque requer menos armazenamento local para cada conexão sináptica, torna menos provável que o algoritmo de retropropagação fique preso em um mínimo local, e fornece soluções efetivas a problemas grandes e difíceis (HAYKIN, 2001). Conforme citado em ANDERSON (1995), normalmente o modo *on-line* mostra-se o mais adequado. Neste trabalho, esse foi o modo de ajuste dos pesos adotado.

Além do programa principal, o programa computacional desenvolvido apresenta três subrotinas: Teste, Escalona, e Linha. A subrotina Teste avalia a eficiência do aprendizado, a subrotina Linha é responsável pela aleatorização e a subrotina Escalona identifica quais os maiores e menores valores das variáveis em estudo.

No início desse programa, são definidos pelo usuário os seguintes parâmetros: número de *inputs*, *outputs*, neurônios ocultos, taxa de aprendizagem, termo de momento, quantidade de exemplos de treinamento, quantidade de exemplos de teste e de iterações desejadas. Além desse, deve-se definir os três parâmetros da modificação delta-barras-delta: k , β e ξ . É interessante observar que, caso deseje-se utilizar o algoritmo de *backpropagation* sem modificação, basta manter esses três parâmetros nulos.

Em seguida, para poder iniciar o treinamento, o programa gera valores aleatórios e baixos dos pesos e *bias* ("chute" inicial). Na sequência, o programa chama a subrotina Escalona e a subrotina Linha, a qual permuta as linhas do conjunto de treinamento de maneira randômica (aleatorização). Entra-se com o arquivo aleatorizado contendo os exemplos de treinamento e o programa realiza o escalonamento das variáveis de entrada no intervalo [0, 1] e as variáveis de saída no intervalo [0,1; 0,9], conforme sugerido em HOSKINS e HIMMELBLAU (1988). Em seguida, são realizados todos os cálculos envolvidos nas fases *forward* e *backward* da retropropagação (Equações 1 a 16).

Para um número grande de iterações N, são calculados simultaneamente os erros de treinamento e teste (através da subrotina Teste), de modo a permitir observar a evolução dos erros com o decorrer do tempo. Finalizado o treinamento, a subrotina determina qual foi o menor erro de teste atingido e em que iteração isso aconteceu. Utilizando os pesos obtidos nessa iteração, a subrotina faz as predições. Estas são comparadas com os valores reais (Y) e é feito um ajuste linear por mínimos quadrados para uma reta representada pela Equação 45, onde coef é o coeficiente angular:

$$\hat{Y} = \text{coef} \cdot Y \quad (45)$$

O programa também calcula o coeficiente de determinação R^2 , de acordo com as Equações 46 a 48.

$$SSE = \sum_{j=1}^M (OL_j - \hat{Y}_j)^2 \quad (46)$$

$$SST = \sum_{j=1}^M (OL_j^2) - \frac{(\sum_{j=1}^M OL_j)^2}{M} \quad (47)$$

$$R^2 = \left(1 - \frac{SSE}{SST} \right) \quad (48)$$

Sendo: \hat{Y} = valor da reta de mínimo quadrado

M = número de exemplos de teste

Quanto mais eficiente for a rede neural, mais próximo de 1 estará o R^2 .

A subrotina de Teste permite também avaliar a influência das variáveis de entrada na saída da rede através da Equação de Garson (Equação 17).

Finalizadas as fases de treinamento e teste, o programa tem a opção de repetir todos os cálculos para novos valores de número de neurônios ocultos, taxa de aprendizagem, etc. Dessa forma, é possível testar todas as possíveis combinações desses parâmetros que governam a eficiência da rede.

É interessante observar que o programa foi escrito de maneira genérica, isto é, considerando mais de uma saída da rede. Dessa forma, caso o problema em estudo apresente várias saídas o usuário pode optar por usar um só neurônio na camada de saída de cada vez ou mais de um neurônio.

CAPÍTULO 7: RESULTADOS E DISCUSSÃO

7.1: Caso (a) - Predição de Propriedades Finais

O trabalho com as redes neurais seguiu os seguintes passos, para todos os casos estudados:

- Obtenção, simultaneamente, dos erros de treinamento e teste com o decorrer das iterações.
- A partir dos pesos que resultaram no menor erro de teste, obter predições.
- Testar outras combinações dos parâmetros da rede a fim de conseguir um aprendizado mais eficiente.

A seguir, será mostrado com mais detalhes o estudo da rede para predição do coeficiente de dilatação térmica na direção circunferencial (α_x). Para todos os outros casos, seguiu-se um roteiro semelhante e portanto, somente serão mostrados os resultados das predições. Verificou-se que todas as redes mostraram um desempenho melhor quando apresentaram apenas 1 neurônio na camada *output* por vez.

A rede para predição do coeficiente de dilatação térmica contou com seis neurônios na camada de entrada e um neurônio na camada de saída. A Figura 21 mostra a evolução dos erros de treinamento e teste para uma rede cujo neurônio de saída representa o coeficiente de dilatação térmica na direção circunferencial até 3000 iterações do programa desenvolvido. Para essa rede, foram considerados oito neurônios ocultos, termo de momento = 0,6 e taxa de aprendizagem = 0,7. Observou-se que a incorporação da modificação delta-barras-delta não tornou o aprendizado mais eficiente, e portanto os parâmetros k , ξ e β foram mantidos nulos.

Como pode ser observado na Figura 21 a seguir, o erro de treinamento diminui com o tempo e atinge seu valor mínimo em cerca de 3000 iterações (0,01908). À medida que o treinamento vai sendo efetuado, a rede vai identificando a relação existente entre as condições de entrada e saída, criando um modelo interno. Quanto mais longo é o

treinamento, maiores são os detalhes incorporados a esse modelo. Se o treinamento for excessivamente longo, as peculiaridades individuais do conjunto de treinamento serão acuradamente modeladas e a rede tenderá a não conseguir generalizar os conceitos para um novo conjunto de *input*, o que é chamado de *overfitting* (ANDERSON, 1995).




Figura 21: Perfis de Erro de Treinamento e Teste para o Coeficiente de Dilatação Térmica na Direção Circunferencial.

A evolução dos erros ilustrada na Figura 21 mostra que o menor erro de teste para o caso do coeficiente de dilatação térmica na direção circunferencial aconteceu em cerca de 1500 iterações ou épocas e que, a partir desse momento, o erro de teste tende a aumentar, isto é, observa-se a ocorrência de *overfitting*. A partir dos pesos correspondentes ao menor erro de teste, foi possível obter os resultados mostrados na Figura 22 e Tabela 13, que comparam os valores reais e preditos pela rede para essa propriedade térmica. Esses resultados revelam uma boa correlação entre os valores desejados (reais) e os gerados pela rede neural (coeficiente de determinação $R^2 = 0,9074$), para os dez exemplos de teste considerados. Resultados semelhantes foram obtidos para o coeficiente de dilatação térmica na direção axial.

É interessante observar que a reta de ajuste exibida na Figura 22 (e em todas as demais mostradas nesse trabalho) passa pela origem e pode ser representada pela Equação 45 do capítulo 6.




Figura 22: Comparação Entre os Valores Reais e Preditos pela Rede Neural para o Coeficiente de Dilatação Térmica na Direção Circunferencial.

Tabela 13: Dados Utilizados na Obtenção da Figura 22.

Valor Real	Valor Predito
2,13	2,1079
2,20	2,18
2,18	2,13
2,04	2,03
2,27	2,31
2,19	2,19
2,05	2,01
2,20	2,20
2,18	2,18
2,08	2,10

Existem parâmetros que controlam a performance da rede e conseqüentemente a sua capacidade de predição, como número de neurônios na camada intermediária, taxa de aprendizagem e termo de momento. Logo, para se desenvolver um modelo efetivo de rede neural é preciso escolher adequadamente esses parâmetros. SWINGLER (1996) e HAYKIN (2001) discutem alguns critérios que podem auxiliar nessa escolha, mas como a rede ótima é particular para o sistema estudado, em geral, a obtenção desses parâmetros é feita por tentativa-e-erro. Neste trabalho, foram testadas várias combinações desses parâmetros, resultantes do treinamento consecutivo de mais de 100 redes neurais. Isso foi possível porque o programa computacional desenvolvido permite que os parâmetros sejam variados consecutivamente. É interessante observar que muitos *softwares* comerciais para


redes neurais não dispõem dessa opção, e o usuário é obrigado a fazer todas as tentativas manualmente, o que geralmente é muito demorado.

A Figura 23 mostra a avaliação da eficiência do aprendizado (realizado até 4000 iterações) através da comparação entre os valores reais (desejados) e preditos pela rede para as seguintes propriedades dos tubos: (a) coeficiente de expansão térmica na direção axial, (b) módulo de elasticidade na tração circunferencial, (c) módulo de elasticidade na tração axial, (d) módulo de cisalhamento (no plano), (e) maior razão de Poisson, (f) tensão de tração circunferencial, (g) tensão de tração axial, (h) tensão de compressão axial. Essa figura exibe apenas os resultados da fase de teste. Comparações baseadas no conjunto de treinamento podem ser observadas na Figura 24.


Como pode ser observado nas Figuras 23 e 24 e também na Tabela 14, as predições foram satisfatórias, considerando-se a baixa quantidade de exemplos de treinamento e teste disponíveis. O pior desempenho considerando o conjunto de teste foi observado para a rede de predição de maior razão de Poisson ($R^2 = 0,8606$) e o melhor desempenho foi observado para a rede de predição de tensão de tração circunferencial ($R^2 = 0,9938$).

A Tabela 14 mostra ainda que, para a maioria dos casos estudados, a modificação delta-barras-delta não resultou em uma melhoria do aprendizado das redes, as quais, utilizando somente o algoritmo de *backpropagation* sem modificação, já apresentavam um bom desempenho. Os resultados de R^2 mostrados nessa tabela correspondem a redes treinadas até o máximo de 4000 iterações, sendo que o menor erro de teste ocorreu na iteração ali indicada.


Um aspecto interessante observado na Figura 23g (tensão de tração axial) é que, para três dos cinco dados considerados, o conjunto de pesos e *bias* gerados é tal que, independente do exemplo fornecido à rede, os resultados das predições são sempre os mesmos. Um dos fatores que pode ser responsável por esta insensibilidade a variações nos dados de entrada pode ser a inadequação do conjunto de dados de treinamento. Esse mesmo comportamento foi observado por LONA BATISTA (1996), ao trabalhar com redes neurais para modelagem do processo de craqueamento catalítico.




(a)



(b)




(c)




(d)


Figura 23: Comparação Entre os Valores de Teste Desejados e Preditos pela Rede Neural para: (a) coeficiente de expansão térmica na direção axial, (b) módulo de elasticidade na tração circunferencial, (c) módulo de elasticidade na tração axial, (d) módulo de cisalhamento (no plano), (e) maior razão de Poisson, (f) tensão de tração circunferencial, (g) tensão de tração axial, (h) tensão de compressão axial.




(e)



(f)




(g)




(h)


Figura 23: Continuação.



(a)




(b)




(c)


Figura 24: Comparação Entre os Valores de Treinamento Desejados (Reais) e Preditos pela Rede Neural para: (a) coeficiente de expansão térmica na direção circunferencial (b) coeficiente de expansão térmica na direção axial, (c) módulo de elasticidade na tração circunferencial, (d) módulo de elasticidade na tração axial, (e) módulo de cisalhamento (no plano), (f) maior razão de Poisson, (g) tensão de tração circunferencial, (h) tensão de tração axial, (i) tensão de compressão axial.




(d)




(e)




(f)



(g)



(h)



(i)

Figura 24: Continuação.

Tabela 14: Parâmetros Utilizados nas Predições, e Valor do R^2 Resultante para o Conjunto de Teste Considerado.

Propriedade	Neurônios Ocultos	Termo de Momento	Taxa de Aprendizagem	k	β	ξ	R^2	Iteração
ax	8	0,6	0,7	0	0	0	0,9074	1500
ay	6	0,4	0,6	0,01	0,01	0,1	0,9767	1073
Ex	6	0,4	0,6	0	0	0	0,9885	4000
Ey	5	0,3	0,5	0	0	0	0,9937	269
S	5	0,3	0,5	0	0	0	0,9905	2553
Ux	3	0,6	0,3	0,01	0,02	0,1	0,8606	108
X	6	0,4	0,6	0	0	0	0,9938	4000
Y	5	0,5	0,6	0,01	0,05	0,01	0,8684	1031
Y'	4	0,3	0,5	0	0	0	0,9809	324

ax = Coeficiente de dilatação térmica na direção circunferencial

ay = Coeficiente de dilatação térmica na direção axial

Ex = Módulo de elasticidade na tração circunferencial

Ey = Módulo de elasticidade na tração axial

S = Módulo de cisalhamento (no plano)

Ux = Maior razão de Poisson

X = Tensão de tração circunferencial (na ruptura)

Y = Tensão de tração axial

Y' = Tensão de compressão axial

7.1.1: Análise dos Pesos

Utilizando os pesos obtidos na fase de aprendizagem, foi construído o histograma mostrado na Figura 25, para o caso do módulo de elasticidade na tração circunferencial (Ex). Essa figura mostra que a maioria dos pesos apresenta valores baixos e que a sua distribuição de frequência apresenta um perfil que se assemelha ao de uma curva gaussiana, o que, segundo SWINGLER (1996) pode ser uma indicação de um treinamento eficiente. Histogramas similares foram encontrados para as demais propriedades.

Dessa forma, além dos valores dos coeficientes de determinação obtidos, também através da análise dos pesos foi possível verificar que o treinamento das redes neurais foi eficiente.




Figura 25: Histograma dos Pesos para o Caso do Módulo de Elasticidade na Tração Circunferencial.

7.1.2: Avaliação da Influência das Variáveis de Entrada

O efeito das variáveis utilizadas como neurônios da camada *input* foi investigado através da Equação de Garson mostrada no capítulo 2 (Equação 17). É interessante observar que nessa equação são utilizados apenas os pesos (não são incluídos os *bias*).

A Tabela 15 mostra a porcentagem de influência da composição global nas sete propriedades mecânicas estudadas. O que os resultados da aplicação da Equação de Garson estão mostrando nesse caso é qual é o papel de cada material no cálculo da propriedade da peça, isto é, como as propriedades mecânicas são influenciadas quando a peça é feita de uma combinação de materiais com propriedades distintas.

Observa-se que o teor de resina, que é o material predominante na maioria dos tubos da Polyplaster considerados neste trabalho, exerce uma grande influência no cálculo dessas propriedades, sendo que a sua influência é mais acentuada no caso da tensão de compressão axial (Y'), onde atinge 50%. Esse resultado é concordante com a literatura que diz que a matriz exerce grande influência nas seguintes propriedades mecânicas: resistência à compressão, à flexão e ao cisalhamento interlaminar. É a matriz quem dita também a processabilidade do compósito e sua resistência ambiental (ILSCHNER *et alii*, 1986).

Observa-se também na Tabela 15, que conforme esperado, as propriedades medidas na direção circunferencial são mais influenciadas pelo teor de fibras contínuas (para E_x e X

tem-se 41% de influência), uma vez que os compósitos apresentam maior resistência na direção da fibra (o padrão de enrolamento das fibras empregado no *filament winding* foi o circunferencial para todos os tubos). Por essa mesma razão, essa variável de entrada mostra menor influência nas propriedades medidas na direção perpendicular às fibras contínuas, isto é, na direção axial (para E_y e Y tem-se 18% e para Y' tem-se 15% de influência).

De acordo com a Tabela 15, as fibras cortadas exercem maior influência nos cálculos do módulo de cisalhamento e do módulo de elasticidade na tração axial.

Tabela 15: Porcentagem de Influência da Composição Global dos Tubos da Polyplaster nas Propriedades Mecânicas.

Propriedade	Influência (%) do Teor de		
	Resina	Fibra Cortada	Fibra Contínua
E_x = Módulo de elasticidade na tração circunferencial	38	21	41
E_y = Módulo de elasticidade na tração axial	46	36	18
S = Módulo de cisalhamento	41	42	18
U_x = Maior razão de Poisson	48	17	36
X = Tensão de tração circunferencial	38	21	41
Y = Tensão de tração axial	48	35	18
Y' = Tensão de compressão axial	50	35	15

A Tabela 16 mostra a influência da composição global e das características geométricas nas duas propriedades térmicas consideradas: coeficiente de dilatação térmica na direção circunferencial e na direção axial. A dilatação térmica traduz o volume adicional necessário para acomodar os átomos e moléculas por estarem vibrando mais rápido e com maior amplitude, devido ao aquecimento (MANO, 1991). De acordo com essa tabela, para o coeficiente na direção axial, os teores de resina e fibra apresentam porcentagens de influência equivalentes, em torno de 20% e as características geométricas também mostram influências equivalentes, porém em menor intensidade (em torno de 12%).

Com relação ao coeficiente de dilatação térmica na direção circunferencial, verifica-se que o diâmetro nominal apresenta apenas 4% de influência, enquanto que o teor de resina apresenta 39%, o que mostra a importância dessa variável de entrada.

Tabela 16: Porcentagem de Influência da Composição Global e da Geometria dos Tubos da Polyplaster nas Propriedades Térmicas.

Propriedade	Influência (%)					
	Teor de Resina	Teor de Fibra Cortada	Teor de Fibra Contínua	Diâmetro Nominal	Espessura da Peça	Peso do Tubo
a_x = Coeficiente de dilatação térmica na direção circunferencial	39	25	14	4	6	12
a_y = Coeficiente de dilatação térmica na direção axial	21	24	20	12	11	12

A Equação de Garson mostra que, além da capacidade de realizar previsões, com as redes neurais também é possível extrair informações sobre como as entradas se relacionam com as saídas do sistema em estudo e que para tanto são utilizados os valores dos pesos.

7.1.3: Otimização do Processo

Neste item, é ilustrada a aplicação do método de superfície-resposta (BAUGHMAN e LIU, 1995) para otimização do processo de fabricação de materiais compósitos com vista à melhoria das propriedades das peças. Esse método consiste em criar um perfil completo de previsões (superfície de respostas) para as variáveis de saída usando redes neurais treinadas e variando-se as variáveis de entrada em toda a faixa de valores abrangida pelo conjunto de treinamento. Através da análise dos perfis, identificam-se as condições ótimas a serem escolhidas.

É importante observar que foram realizados dois tipos de otimização neste trabalho: (i) otimização da arquitetura das redes neurais, através da escolha dos melhores valores para os vários parâmetros que governam a eficiência da rede (empregando a subrotina de Teste) e (ii) otimização do processo de *filament winding*, que será mostrado neste item.

A Tabela 17 mostra alguns dos resultados encontrados considerando-se apenas o módulo de elasticidade na tração circunferencial (E_x), que deve ser o maior possível, e o coeficiente de dilatação térmica na direção circunferencial (a_x), que deve ser o menor

possível. Dessa forma, pretende-se ilustrar como é possível otimizar a composição da peça de forma que ela apresente as melhores propriedades possíveis.

Tabela 17: Algumas Predições das Redes Neurais para Otimização das Peças.

Resina (% em peso)	Fibra Cortada (% em peso)	Fibra Contínua (% em peso)	Ex (10^{10} Pa)	ax (10^{-5} m/°C.m)
45,0	23,0	32,0	1,95	2,06
45,0	37,0	18,0	1,67	2,07
50,0	20,0	30,0	1,84	2,20
55,0	20,0	25,0	1,57	2,31
55,0	22,0	23,0	1,51	2,32
60,0	25,0	15,0	1,14	2,36
60,0	30,0	10,0	1,05	2,37
46,0	30,0	24,0	1,80	2,06
46,0	35,0	19,0	1,67	2,07
47,0	37,0	16,0	1,55	2,08
48,0	37,0	15,0	1,49	2,09
49,0	20,0	31,0	1,88	2,16
51,0	25,0	24,0	1,66	2,21
51,0	30,0	19,0	1,51	2,19
52,0	37,0	11,0	1,25	2,22
53,0	20,0	27,0	1,69	2,28
54,0	30,0	16,0	1,32	2,33
54,0	37,0	9,0	1,15	2,32
57,0	30,0	13,0	1,17	2,36
57,0	37,0	6,0	1,03	2,36
58,0	20,0	22,0	1,38	2,34
59,0	35,0	6,0	1,01	2,37
59,0	36,0	5,0	0,99	2,37
58,0	30,0	12,0	1,12	2,36
58,0	37,0	5,0	1,01	2,37
59,0	20,0	21,0	1,32	2,34
59,0	25,0	16,0	1,19	2,35
59,0	30,0	11,0	1,08	2,36
56,0	37,0	7,0	1,07	2,36
57,0	20,0	23,0	1,44	2,33
57,0	25,0	18,0	1,29	2,35
57,0	30,0	13,0	1,17	2,36
50,0	23,0	27,0	1,77	2,18
50,0	26,0	24,0	1,69	2,16

As características geométricas das peças não foram variadas, uma vez que essas dependem da aplicação a que se destina a peça, e adotou-se arbitrariamente, para que fosse possível realizar os cálculos, um tubo com $DN = 1000,0$ mm, espessura = 15,0 mm e peso = 76,6 kg/m.

Foram variados, na Tabela 17, os valores das composições globais dentro das seguintes faixas, que restringem o conjunto de treinamento:

- Teor de Resina: 45 a 60%
- Teor de Fibra Cortada: 20 a 37%
- Teor de Fibra Contínua: 5 a 32%

Observa-se que, para cada combinação de composição, é possível obter um determinado valor de propriedade. As composições que levaram ao maior valor de Ex (1,95) e simultaneamente ao menor valor de ax (2,06) foram: resina = 45%, fibra cortada = 23% e fibra contínua = 32%.

Nesse exemplo, foram testadas variações das três variáveis de entrada da rede. Em BAUGHMAN e LIU (1995), é ilustrado um problema (predição da espessura e do tamanho de poros de peças de material compósito obtidas através do processo de moldagem) onde existem sete *inputs*; naquele caso, os autores usaram técnicas estatísticas (análise de variância) para definir quais os três *inputs* mais importantes (que foram variados) e os demais foram mantidos em seus valores médios. É interessante observar que em um caso como aquele onde existem muitas variáveis de entrada, pode se usar a Equação de Garson para analisar a influência dessas variáveis, conforme foi mostrado no item anterior.

7.2: Caso (b) - Predição de Temperatura

A Figura 26 ilustra a evolução dos erros de treinamento e teste, até 4000 iterações, para a rede neural que avalia a temperatura medida no interior de cilindros de *filament winding*. Os dados utilizados no treinamento da rede foram obtidos através do *software*

Windthick, que é baseado no modelo Lee-Springer. Para essa rede, foram utilizados 10 neurônios ocultos, termo de momento igual a 0,8 e taxa de aprendizagem igual a 0,5. A escolha da melhor combinação desses parâmetros foi realizada automaticamente através do programa computacional desenvolvido, que repetiu o treinamento da rede muitas vezes. Observou-se que a incorporação da modificação delta-barra-delta não tornou o aprendizado mais eficiente, e portanto os parâmetros k , ξ e β foram mantidos nulos.




Figura 26: Perfis de Erro de Treinamento e Teste para a Rede de Predição de Temperatura no Interior de Cilindros de *Filament Winding*.

A Figura 27 compara os valores desejados com os valores gerados pela rede neural que prediz a distribuição de temperatura no interior dos cilindros. Essas predições foram realizadas utilizando-se os pesos correspondentes ao menor erro de teste, que, conforme mostra a Figura 26, aconteceu em 4000 iterações. Os coeficientes de determinação encontrados para os conjuntos de treinamento ($R^2 = 0,9958$) e de teste ($R^2 = 0,9927$) mostram que o aprendizado da rede foi bastante eficiente.




Figura 27: Comparação Entre os Valores de Temperatura Desejados e Gerados pela Rede Neural para os Conjuntos de: (a) Teste e (b) Treinamento.

Utilizando os pesos obtidos durante a fase de treinamento, foram obtidos perfis de temperatura, em diferentes pontos da peça, para quatro cilindros mostrados em CALIUS *et alii* (1990) e cujas características estão na Tabela 12 do capítulo 6. Todos os cilindros foram fabricados com *prepregs* de resina Fiberite 976 e fibra T-300. Os resultados obtidos com as redes neurais foram comparados com os resultados experimentais reportados naquele artigo (Figura 28).

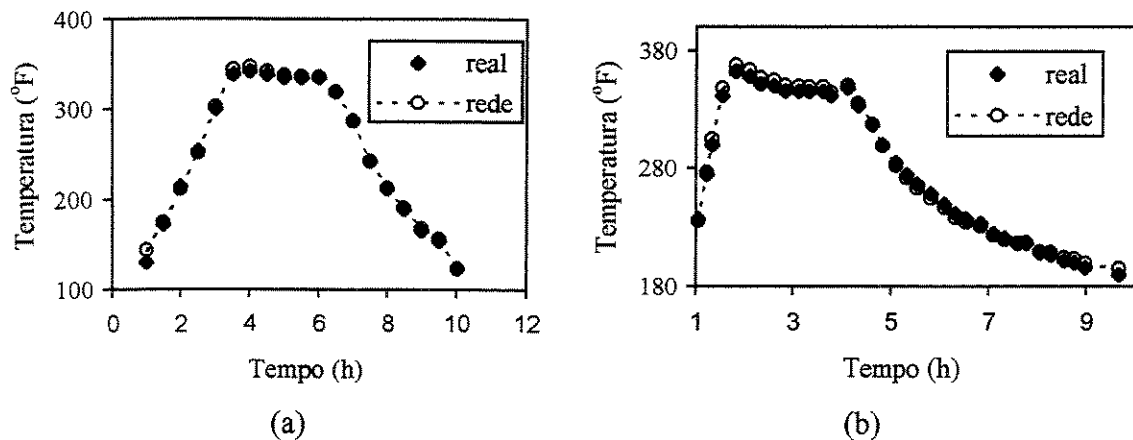


Figura 28: Comparação entre os Valores de Temperatura Gerados pela Rede Neural e os Valores Experimentais Reportados em CALIUS *et alii* (1990) para: (a) cilindro A na metade da peça, (b) cilindro B na camada inferior da peça, (c) cilindro C na metade da peça, (d) cilindro C a 3/4 da superfície externa da peça e (e) cilindro D na metade da peça.

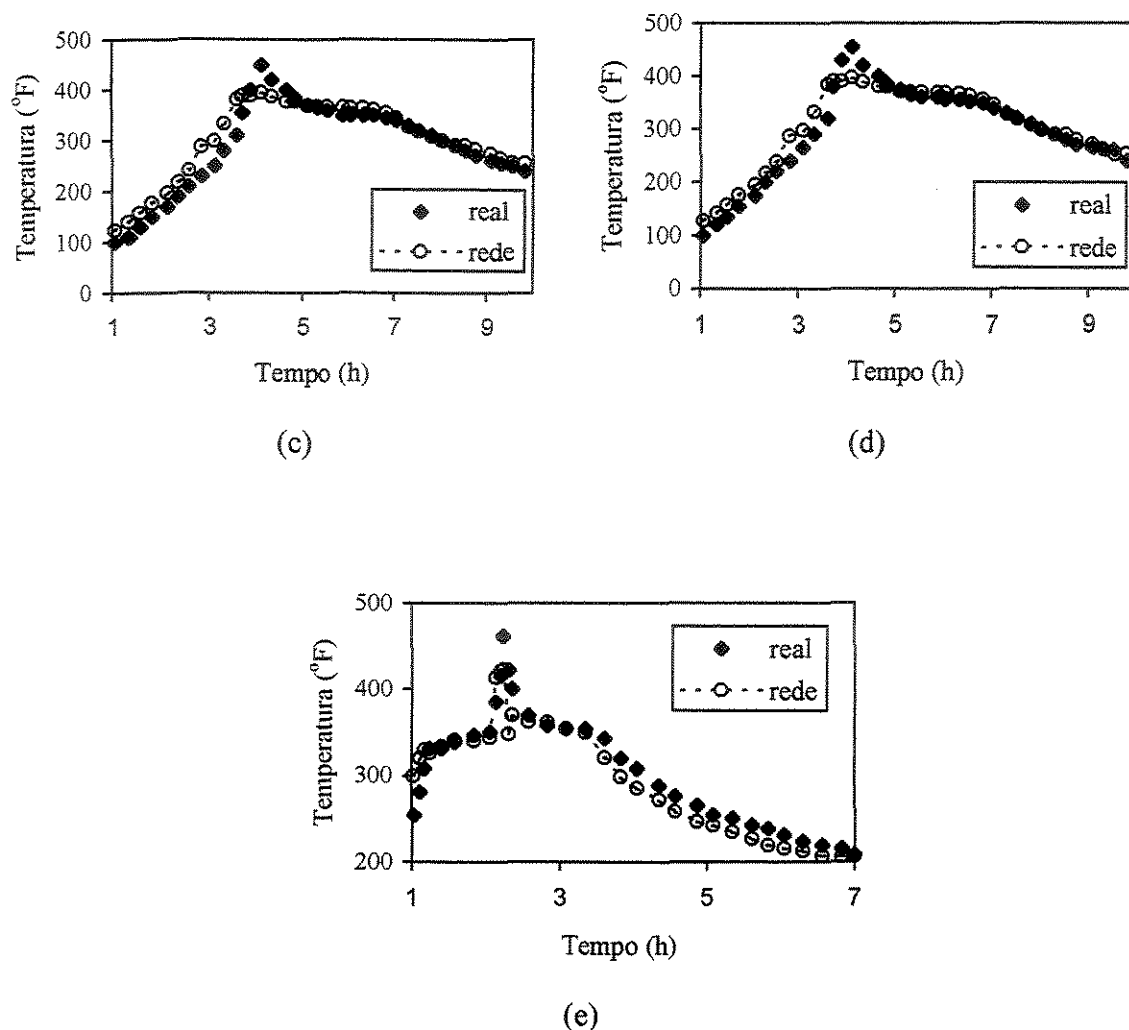


Figura 28: Continuação.

Observa-se uma concordância entre os resultados gerados pela rede neural e os valores experimentais para todos os cilindros, em especial para os cilindros A e B. Com relação às peças C e D, os desvios observados para alguns pontos podem estar associados ao fato de, para essas peças, as temperaturas medidas na camada mais externa diferirem das temperaturas medidas na superfície mais interna do mandril, como ilustra a Figura 29 para o cilindro C. Esses dois conjuntos de temperatura devem ser especificados no *software* Windthick como condição de contorno e foram considerados, para os conjuntos de treinamento da Tabela 11, como sendo iguais. Embora essa suposição possa não ser realista, não havia nenhuma informação sobre o perfil de temperatura do mandril e, ao invés de utilizar valores arbitrários para a temperatura nessa posição, optou-se por mantê-la

igual à temperatura na superfície da peça. É interessante observar que se esse tipo de informação estivesse disponível, mais um neurônio poderia ter sido incluído na camada *input*, representando a temperatura no mandril.




Figura 29: Temperaturas Medidas nas Superfícies da Peça e do Mandril, para o Cilindro C (CALIUS *et alii*, 1990).

Outro aspecto que pode ter contribuído para os desvios de resultado dos cilindros C e D da Figura 28 foi a utilização de alguns valores experimentais de temperatura fora da faixa do conjunto que foi definido para treinamento da rede (valores experimentais: temperatura máxima na superfície = 442,7 °F; conjunto de treinamento: temperatura máxima na superfície = 400,0 °F). Uma vez que a rede neural não é capaz de extrapolar (GUIMARÃES e MCGREAVY, 1995), foram gerados valores mais distantes dos valores desejados. Ainda assim, os perfis obtidos pela rede neural são bastante próximos dos obtidos experimentalmente.

Conhecendo-se os valores de temperatura no interior da peça, pode-se ajustar os valores das variáveis de processo de forma a manter a temperatura uniforme em todos os pontos no interior do material e abaixo do máximo valor permitido durante todo o tempo de processamento. Além disso, através desses valores de temperatura é possível obter informações sobre viscosidade e grau de cura no interior da peça através de correlações (para as resinas consideradas nesse trabalho, correlações podem ser encontradas em CALIUS *et alii*, 1990). Com isso, pode-se ajustar as condições operacionais para que a peça seja completamente curada e de maneira uniforme, sendo o tempo de processamento o menor possível (seleção do ciclo de cura).

7.2.1: Avaliação da Influência das Variáveis de Entrada

O efeito das variáveis utilizadas como neurônios da camada *input* foi investigado através da Equação de Garson e os resultados são mostrados na Tabela 18.

Tabela 18: Porcentagem de Influência das Variáveis de Entrada no Cálculo da Temperatura no Interior de Cilindros Compósitos.

Densidade do Compósito	Calor Específico do Compósito	Condutividade Térmica do Compósito	Espessura da Peça	Tempo	T superfície	Altura da Medição
12	8	12	11	16	31	10

Como pode ser observado na Tabela 18, a temperatura medida na superfície exterior da peça exerce, conforme esperado, a maior influência (31%) no cálculo da distribuição de temperatura no interior da peça. Em segundo lugar, tem-se o tempo (16%). As demais variáveis exercem influências semelhantes (em torno de 11%), sendo que o calor específico é a propriedade que menos influência (8%) o comportamento térmico da peça durante a etapa de cura. Esses resultados mostram que as variáveis utilizadas como *input* da rede neural foram adequadamente escolhidas, uma vez que todas são importantes para a predição da propriedade estudada.

CAPÍTULO 8: CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS

O uso dos compósitos poliméricos - materiais formados por uma matriz polimérica e um reforço, normalmente uma fibra - vem crescendo nas últimas décadas, devido as suas muitas vantagens em relação aos materiais convencionais de engenharia. Dentre os métodos de fabricação de compósitos poliméricos, o *filament winding* se destaca na manufatura de peças como tubos e tanques, por apresentar baixo custo e permitir alta produção e uniformidade de propriedades, entre outras vantagens.

Neste trabalho, foram investigadas possibilidades de aplicação de rede neural, uma poderosa ferramenta computacional inspirada no funcionamento do cérebro humano, no processo de *filament winding*. Foram definidos dois casos-estudo.

No caso (a), foram realizadas previsões de nove propriedades físicas que definem a qualidade da peça final. Os resultados encontrados foram satisfatórios, apesar da baixa quantidade de exemplos de treinamento disponibilizada pela empresa Polyplaster. Para esse caso, também foram analisadas as influências das entradas nas saídas do sistema através da Equação de Garson e ilustrou-se o método de otimização de superfície-resposta para o módulo de elasticidade na tração circunferencial e coeficiente de dilatação na direção circunferencial.

No caso (b), redes neurais foram utilizadas para previsão das mudanças de temperatura no interior de peças, que ocorrem devido à transferência de calor através das superfícies e do calor gerado pelas reações químicas da resina durante o processo de cura. Os dados de treinamento foram obtidos através do modelo Lee-Springer para cilindros de matriz termorrígida. Os resultados encontrados mostraram a eficiência do aprendizado da rede. Utilizando-se os valores dos pesos, o treinamento foi validado com dados experimentais da literatura.

Para o trabalho com as redes neurais, foi desenvolvido um programa computacional baseado no algoritmo de retropropagação (incorporando a modificação delta-barras-delta) que dispõe de várias características importantes como: calcula os perfis de erro de treinamento e também de teste (simultaneamente) para uma quantidade grande de iterações, identifica o menor erro de teste e, com os pesos correspondentes, faz previsões e calcula o coeficiente de determinação, realiza o escalonamento das variáveis, permite aleatorizações

dos exemplos de treinamento em iterações especificadas pelo usuário, permite escolha automática dos parâmetros da rede e permite avaliar a influência das entradas nas saídas do sistema através da Equação de Garson.

Com relação a sugestões para trabalhos futuros, neste trabalho, investigou-se, no caso (b), a possibilidade de predição da distribuição de temperatura no interior de peças de material compósito, utilizando como uma das variáveis de entrada da rede, a temperatura medida na superfície da peça (que é a condição de contorno utilizada no modelo Lee-Springer). Uma outra possibilidade, poderá ser, ao invés daquela temperatura, a utilização da temperatura aplicada como *input* da rede neural.

Outra sugestão é a utilização de redes neurais para predição de outras propriedades que afetam a qualidade do produto final, como formação e crescimento de poros, e movimentação das fibras durante o processo de enrolamento e cura. Redes neurais poderiam ser utilizadas também para otimização do processo de *filament winding* considerando todas essas variáveis.

Uma vez que as exigências do mercado frente à qualidade e ao custo dos produtos estão cada vez maiores, a obtenção de uma ferramenta computacional que possibilite definir condições a fim de melhorar o processo é muito importante.

Embora a metodologia aqui proposta seja diretamente aplicada ao processo de *filament winding*, a mesma sistemática desenvolvida poderá ser certamente utilizada em outros processos de fabricação de materiais compósitos, envolvendo diferentes sistemas fibra-resina termorrígida e também termoplástica. O desenvolvimento deste procedimento poderá assim contribuir de modo importante para a melhoria futura da qualidade das indústrias nacionais de compósitos.

Aqui no Brasil, muitas indústrias, tais como a Polyplaster, foram e estão sendo implantadas, com o objetivo de produzir tubos para transportar fluidos a alta pressão submersos em ambientes corrosivos (uso bastante difundido no transporte de água e na indústria petrolífera), pisos especiais resistentes à corrosão e a chamas para plataformas de petróleo, tanques de armazenamento de fluidos, escadas de incêndio, peças para aviões e carros, materiais esportivos, entre outros.

Apesar da América do Sul representar atualmente apenas 3% do mercado global de compósitos poliméricos, o crescimento anual do setor nessa região tem sido o maior de

todo o mundo, demonstrando o imenso espaço que existe para esses materiais. Sendo o Brasil o líder desse mercado na América do Sul, percebe-se a potencialidade deste setor produtivo e a necessidade de se aumentar a sua competitividade, através de pesquisas e aprimoramento de recursos humanos.

BIBLIOGRAFIA

- ADAMS, D. F. Comprehensive composite materials: test methods, nondestructive evaluation, and smart materials. Reino Unido: Elsevier Science, 2000. Cap. 5.06: Test methods for mechanical properties, p.113-148.
- ANDERSON, J. A. An introduction to neural networks. EUA: MIT Press, 1995, 650 p.
- AGAH-TEHRANI, A. , TENG, H. Analysis of fiber motion during wet filament winding of composite cylinders with arbitrary thickness. International Journal of Solids Structures, v.29, n.21, p.2649-2668, 1992.
- AGARWAL, B. D. , BROUTMAN, L. J. Analysis and performance of fiber composites. 2.ed. EUA: John Wiley & Sons, 1990, 472 p.
- BANERJEE, A. , SUN, L. , MANTELL, S. C. , COHEN, D. Model and experimental study of fiber motion in wet filament winding. Composites: Part A, v.29A, p.251-263, 1998.
- BANNISTER, M. Challenges for composites in the next millennium - a reinforcement perspective. Composites: Part A, v. 2, p.901-910, 2001.
- BAUGHMAN, D. R. , LIU, Y. A. Neural networks in bioprocessing and chemical engineering. EUA: Academic Press, 1995, 488 p.
- BILLMEYER Jr., F. W. Textbook of polymer science. 3.ed., EUA: John Wiley & Sons, 1984, 608 p.
- BOGER, Z. Experience in industrial plant model development using large-scale artificial neural networks. Information Sciences, v.101, p.203-216, 1997.
- CALADO, V. M. A. , ADVANI, S. G. Processing of continuous fiber reinforced composites. EUA: Hanser Publisher, 1999. Cap. 2: Thermoset cure kinetics and rheology, p.32-107.
- CALIUS, E. P. , SPRINGER, G. S. A model of filament-wound thin cylinders. International Journal of Solids and Structures, v.26, n.3, p.271-297, 1990.
- CALIUS, E. P. , LEE, S. , SPRINGER, G. S. Filament winding cylinders: II. validation of the process model. Journal of Composite Materials, v.24, p.1299-1343, 1990.
- CHAMIS, C. C. Simplified composite micromechanics equations for hygral, thermal, and mechanical properties. SAMPE Quarterly, p.14-23, abril 1984.
- CHAWLA, K. K. Composite materials: science and engineering. Alemanha: Springer-Verlag, 1987, 292 p.
-

- CHEN, J. , JANG, S. , WONG, D. S. H. , MA, C. M. , LIN, J. Optimal design of filament winding using neural network experimental design scheme. *Journal of Composite Materials*, v.33, p.2281-2300, 1999.
- CHTIOUL, Y. , PANIGRAHI, S. , FRANCL, L. A. Generalized regression neural network and its application for leaf wetness prediction to forecast plant disease. *Chemometrics and Intelligent Laboratory Systems*, v.48, p.47-58, 1999.
- COHEN, D. Influence of filament winding parameters on composite vessel quality and strength. *Composites: Part A*, v.28A, p.1035-1047, 1997.
- EBUBE, N. K. , ABABIO, G. O. , ADEYEYE, C. M. Preformulation studies and characterization of the physicochemical properties of amorphous polymers using artificial neural networks. *International Journal of Pharmaceutics*, v.196, p.27-35, 2000.
- EDWARDS, K. L. An overview of the technology of fibre-reinforced plastics for design purposes. *Materials and Design*, v.19, p.1-10, 1998.
- ELGIBALY, A. A. , ELKAMEL, A. M. A new correlation for predicting hydrate formation conditions for various gas mixtures and inhibitors. *Fluid Phase Equilibria*, v.152, p.23-42, 1998.
- FELDMAN, D. *Polymeric building materials*. Irlanda do Norte: Elsevier Applied Science, 1989, 576 p.
- GARSON, G. D. Interpreting neural-networks connection weights. *AI Expert*, p.47-59, abril 1991.
- GOLDSWORTHY, W. B. *Encyclopedia of polymer science and engineering*. 2.ed. EUA: John Wiley & Sons, 1986. v. 4: Composites, fabrication, p.1-148.
- GOROVAYA, T. A. , KOROTKOV, V. N. Quick cure of thermosetting composites. *Composites: Part A*, v. 27, p.953-960, 1996.
- GUIMARÃES, P. R. B. , MCGREAVY, C. Flow of information through an artificial neural network. *Computers and Chemical Engineering*, v.19, p.S741-746, 1995.
- HAYKIN, S. *Neural networks, a comprehensive foundation*. EUA: Macmillan College, 1994, 696 p.
- HAYKIN, S. *Redes neurais, princípios e práticas*. 2.ed., Porto Alegre: Bookman, 2001, 900 p.
-

- HOSKINS, J. C. , HIMMELBLAU, D. M. Artificial neural network models of knowledge representation in chemical engineering. *Computers and Chemical Engineering*, v.12, n.9/10, p.881-890, 1988.
- ILSCHNER, B. , LEES, J. K. , DHINGRA, A. K. Ullmann's encyclopedia of industrial chemistry. 5.ed Alemanha: VCH, 1986. v.A7: Composite Materials, p.384-394.
- JACOB, A. Automation sets filament winding on the right path. *Reinforced Plastics*, p.48-50, setembro 1998.
- JACOB, A. Brazil offers good potencial for composites. *Reinforced Plastics*, p.40-45, novembro 1999.
- KARBHARI, V. M. , ZHAO, L. Use of composites for 21st century civil infrastructure. *Computer Methods in Applied Mechanics and Engineering*, v.185, p.433-454, 2000.
- KONDERLA, P. , MOKANEK, T. Comparasion of two methods for the analysis of composite material. *Journal of Materials Processing Technology*, v.106, p.87-93, 2000.
- LEE, J. A. , ALMOND, D. P. , HARRIS, B. The use of neural networks for the prediction of fatigue lives of composite materials. *Composites: Part A*, v.30, p.1159-1169, 1999.
- LEE, S. , SPRINGER, G. S. Filament winding cylinders: I. process model. *Journal of Composite Materials*, v.24, p.1270-1298, 1990 (a).
- LEE, S. , SPRINGER, G. S. Filament winding cylinders: III. selection of the process variables. *Journal of Composite Materials*, v.24, p.1344-1366, 1990 (b).
- LEE, S. , SPRINGER, G. S. Effects of cure on the mechanical properties of composites. *Journal of Composite Materials*, v.22, p.15-29, 1988.
- LONA BATISTA, L. M. F. Desenvolvimento de *software* usando modelos determinísticos e redes neurais para o processo de craqueamento catalítico. Campinas: Faculdade de Engenharia Química, Universidade Estadual de Campinas, 1996. 256 p. Tese (Doutorado).
- LOOS, A. C. , SPRINGER, G. S. Curing of epoxy matrix composites. *Journal of Composite Materials*, v.17, p.135-169, março 1983.
- MANO, E. B. Polímeros como materiais de engenharia. São Paulo: Edgard Blücher, 1991, 197 p.
- MANTELL, S. C. , COHEN, D. Processing of continous fiber reinforced composites. EUA: Hanser Publisher, 1999. Cap. 13: Filament winding. p.388-417.
-

- MANTELL, S. C. , SPRINGER, G. S. Filament winding process model. *Composite Structures*, v.27, n.1/2, p.141-147, 1994.
- MATTHEWS, F. L. , RAWLINGS, R. D. *Composites materials: engineering and science*. Reino Unido: Chapman & Hall, 1996, 470 p.
- MAZUMDAR, S. K. , HOA, S. V. Analytical models for low cost manufacturing of composite components by filament winding, part I: direct kinematics. *Journal of Composite Materials*, v.29, n.11, p.1515-1541, 1995 (a).
- MAZUMDAR, S. K. , HOA, S. V. Analytical models for low cost manufacturing of composite components by filament winding, part II: inverse kinematics. *Journal of Composite Materials*, v.29, n.13, p.1762-1789, 1995 (b).
- MEERT, K. , RIJCKAERT, M. Intelligent modelling in the chemical process industry with neural networks: a case study. *Computers and Chemical Engineering*, v.22, p.S587-593, 1998.
- MELVIN, D. G. , NIRANJAN, M. , PRAGER, R. W. , TRULL, A. K. , HUGLES, V. F. Neurocomputing versus linear statistical techniques applied to liver transplant monitoring: a comparative study. *IEE Transactions on Biomedical Engineering*, v.47, n.8, p.1036-1043, 2000.
- PARNAS, L. , KATIRCI, N. Design of fiber-reinforced composite pressure vessels under various loading conditions. *Composite Structures*, v.58, p.83-95, 2002.
- PETERS, S. T. , HUMPHREY, D. W. *Engineered materials handbook: composites*. EUA: ASM, 1989. v. 1: Filament winding, p.503-518.
- Revista do Plástico Reforçado, n.16, p. 12, 17, 40-50, novembro/dezembro 2000.
- SHEN, F. C. A filament-wound structure technology overview. *Materials Chemistry and Physics*, v.42, p.96-100, 1995.
- SOUTHAM, D. Filament wound pipe, an economic solution. *Reinforced Plastics*, p. 40-43, julho/agosto 2000.
- SPOERRE, J. K. , KENDALL, K. N. Modeling and optimization of a thermoplastic composites stamping process. *Computers and Industrial Engineering*, v.35, n.1/2, p.45-48, 1998.
- SAVKOVIC-STEVANOVIC, J. Neural networks for process analysis and optimization: modeling and applications. *Computers and Chemical Engineering*, v.18, n.11/12, p.149-1155, 1994.
-

-
- SUMPTER, B. G. , NOID, D. W. On the design, analysis, and characterization of materials using computational neural networks. *Annual Review of Material Science*, v.26, p.223-277, 1996.
- SWINGLER, K. Applying neural networks: a practical guide. Londres: Academic Press, 1996, 303 p.
- TANG, J.-M. , LEE, W. I. , SPRINGER, G. S. Effects of cure pressure on resin flow, voids, and mechanical properties. *Journal of Composite Materials*, v.21, p.421-440, maio 1987.
- TARNOPOL'SKII, Y. M. , KULAKOV, V. L. , MUNGALOV, D. D. Composites in offshore technology in the next century. *Mechanics of Composite Materials*, v.35, n.5, p.365-372, 1999.
- TWU, J.-T. , LEE, L. J. Application of artificial neural networks for the optimal design of sheet molding compound (SMC) compression molding. *Polymer Composites*, v.16, n.5, p.400-408, 1995.
- VERT, F. T. , GIMÉNEZ, F. P. , SALVADOR, M. T. S. , MARCH, F. J. G. , OLTRA, J. J. Artificial neural network applied to the discrimination of antibacterial activity by topological methods. *Journal of Molecular Structure*, v.504, p.249-259, 2000.
- VON ZUBEN, F. J. Redes neurais aplicadas ao controle de máquina de indução. Campinas: Faculdade de Engenharia Elétrica, Universidade Estadual de Campinas, 1993. 255 p. Tese (Mestrado).
- WILCOX, J. A. D. , WRIGHT, D. T. Towards pultrusion process optimization using artificial neural networks. *Journal of Materials Processing Technology*, v.83, n.1, p.131-141, 1998.
- ZHAO, L. , MANTELL, S. C. , COHEN, D. , McPEAK, R. Finite element modeling of the filament winding process. *Composite Structures*, v.52, p.499-510, 2001.
-