

DISSERTAÇÃO

27 de junho de 2024

Rede Neural Artificial aplicada na predição de propriedades mecânicas de compósitos unidirecionais reforçados com fibras naturais

Tiago Luis Santos Silva

Alagoinhas/BA

eng.tiagoluis@gmail.com

orientado por:

Dr. Genilson Cunha de Oliveira Filho

Professor da Universidade do Estado da Bahia



Universidade do Estado da Bahia

Departamento de Ciências Exatas e da Terra II

Programa de Pós-Graduação em Modelagem e Simulação de Biosistemas

Tiago Luis Santos Silva

Rede Neural Artificial aplicada na predição de propriedades mecânicas de compósitos unidirecionais reforçados com fibras naturais

Dissertação de Mestrado submetida a Universidade do Estado da Bahia, no Programa de Pós-Graduação em Modelagem e Simulação de Biosistemas, como requisito parcial para a obtenção do título de Mestre em Modelagem e Simulação de Biosistemas.

Área de conhecimento: Interdisciplinar

Área de Concentração: Modelagem Aplicada a Biosistemas

Linha de Pesquisa: Modelagem e Otimização de Biosistemas

Orientador: Dr. Genilson Cunha de Oliveira Filho

coorientador: Dr. Alexandre do Nascimento Silva- (UESC)

URL do documento original: www.ppgmsb.uneb.br/tcc

Alagoinhas/BA

27/06/2024

Sistema de Bibliotecas da UNEB
Biblioteca Carlos Drummond de Andrade – Campus II
Manoela Ribeiro Vieira
Bibliotecária – CRB 5/1768

S586r Silva, Tiago Luis Santos Silva
Rede Neural Artificial aplicada na predição de propriedades mecânicas de compósitos unidirecionais reforçados com fibras naturais / Tiago Luis Santos Silva – Alagoinhas, 2024.
70f.:il

Orientador: Prof. Dr. Genilson Cunha de Oliveira Filho
Coorientador: Prof. Dr. Alexandre do Nascimento Silva

Dissertação (Mestrado) – Universidade do Estado da Bahia, Programa de Pós-graduação em Modelagem e Simulação de Biosistemas - Departamento de Ciências Exatas e da Terra. Mestrado em Modelagem e Simulação de Biosistemas, 2024.

1. Fibras Naturais 2. Módulo de Elasticidade Transversal 3. Rede Neural Artificial I. Oliveira Filho, Genilson Cunha de. II. Silva, Alexandre do Nascimento III. Título.

FOLHA DE APROVAÇÃO
"REDES NEURAIS ARTIFICIAIS APLICADAS NA PREDIÇÃO DE PROPRIEDADES
MECÂNICAS DE COMPÓSITOS UNIDIRECIONAIS REFORÇADOS COM FIBRAS
NATURAIS."

TIAGO LUIS SANTOS SILVA

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem e Simulação de Biosistemas – PPGMSB, em 27 de junho de 2024, como requisito parcial para obtenção do grau de Mestre em Modelagem e Simulação de Biosistemas pela Universidade do Estado da Bahia, conforme avaliação da Banca Examinadora:

 Documento assinado digitalmente
GENILSON CUNHA DE OLIVEIRA FILHO
Data: 16/09/2024 20:47:14-0300
Verifique em <https://validar.it.gov.br>

Professor(a) Dr.(a) GENILSON CUNHA DE OLIVEIRA FILHO
UNEB
Doutorado em Engenharia Mecânica
Universidade Federal de Pernambuco

Professor(a) Dr.(a) ALEXANDRE DO NASCIMENTO SILVA
UNEB
Doutorado em Modelagem Computacional e Tecnologia Industrial
SENAI - Departamento Regional da Bahia

 Documento assinado digitalmente
ALEXANDRE DO NASCIMENTO SILVA
Data: 09/09/2024 12:50:48-0300
Verifique em <https://validar.it.gov.br>

Professor(a) Dr.(a) JOSE ROBERTO DE ARAUJO FONTOURA
UNEB
Doutorado em Difusão do Conhecimento
Universidade Federal da Bahia

 Documento assinado digitalmente
JOSE ROBERTO DE ARAUJO FONTOURA
Data: 08/08/2024 15:46:31-0300
Verifique em <https://validar.it.gov.br>

Professor(a) Dr.(a) FREDE DE OLIVEIRA CARVALHO
UFAL
Doutorado em Engenharia Química
Universidade Estadual de Campinas

 Documento assinado digitalmente
FREDE DE OLIVEIRA CARVALHO
Data: 28/08/2024 15:03:30-0300
Verifique em <https://validar.it.gov.br>

Dedicatória

Dedico este trabalho primeiramente a minha família, em seguida a todos que contribuíram direta e indiretamente para a realização de mais essa etapa da minha vida profissional .:

Resumo

Esse trabalho tem como principal objetivo aplicar modelos de rede neural artificial (RNA) para a análise das propriedades de um compósito unidirecional reforçado com fibras naturais, sendo capaz de fornecer os valores teóricos das propriedades mecânicas como o módulo de elasticidade transversal do compósito. E ainda, com esses valores obtidos, estabelecer uma relação com o modelo de Halpin-Tsai, através do coeficiente de correlação e do erro médio quadrático. Para tanto, foi necessário o uso de um conjunto de dados que foi dividido em duas partes, uma parte sendo utilizada para o treinamento e a outra para teste da RNA. Para este trabalho, foram desenvolvidos três tipos de arquiteturas de rede distintas: uma com apenas duas entradas, outra com três entradas e a última consistindo em uma arquitetura híbrida que combina uma RNA com um modelo desenvolvido por Halpin-Tsai. Após o treinamento dos algoritmos, os resultados demonstram que o uso de RNA se mostra bastante promissor, já que os resultados do modelo híbrido (RNA/Halpin-Tsai) apresentam maiores valores de coeficiente de correlação e menores valores de erro médio quadrático. Enquanto a RNA com duas entradas falhou na modelagem, a de três entradas mostrou resultados positivos em comparação com o modelo Halpin-Tsai. A eficácia do modelo híbrido reside na capacidade de generalizar, combinando a RNA e os dados do Halpin-Tsai.

Palavras-chave: Fibras Naturais, Compósitos Unidirecionais, Módulo de Elasticidade Transversal, Modelo de Halpin-Tsai, Rede Neural Artificial (RNA).

ABSTRACT

This work aims to apply artificial neural network (ANN) models for the analysis of properties of a unidirectional composite reinforced with natural fibers, thus providing theoretical values of mechanical properties such as the transverse elasticity modulus of the composite. Furthermore, with these obtained values, establishing a relationship with the Halpin-Tsai model, through the correlation coefficient and mean square error. To do so, it was necessary to use a dataset that was divided into two parts, one part being used for training and the other for ANN testing. For this work, three different network architectures were developed: one with only two inputs, another with three inputs, and the last consisting of a hybrid architecture that combines an ANN with a model developed by Halpin-Tsai. After training the algorithms, the results demonstrate that the use of ANN is quite promising, as the results of the hybrid model (ANN/Halpin-Tsai) show higher correlation coefficient values and lower mean square error values. While the ANN with two inputs failed in modeling, the one with three inputs showed positive results compared to the Halpin-Tsai model. The effectiveness of the hybrid model lies in its ability to generalize, combining the ANN and the Halpin-Tsai data.

Keywords: Natural Fibers, Unidirectional Composites, Transverse Elasticity Modulus, Halpin-Tsai Model, Artificial Neural Network (ANN).

Lista de Siglas

E_2 - Módulo de Elasticidade Transversal

E_1 - Módulo de Elasticidade Longitudinal

E_f - Módulo de Elasticidade da Fibra

E_m - Módulo de Elasticidade da Matriz

G_{12} - Módulo de Cisalhamento

$\sigma_{c,l}^*$ - Limite de resistência do compósito na direção longitudinal

X_t - Tensão última à tração longitudinal

m_c - Massa do Compósito

m_f - Massa da Fibra

m_m - Massa da Matriz

M_c - Fração de Massa do Compósito

M_f - Fração de Massa da Fibra

M_m - Fração de Massa da Matriz

M - Fração Mássica

r - Coeficiente de Correlação

V_c - Fração Volumétrica do Compósito

V_f - Fração Volumétrica da Fibra

V_m - Fração Volumétrica da Matriz

V_v - Fração Volumétrica de Vazios

ν_{12} - Coeficiente de Poisson Maior

LISTA DE SIGLAS

ν_{21} - Coeficiente de Poisson Menor

ν_{23} - Coeficiente de Poisson na direção 23

$E_{f_{max}}$ - Módulo de Elasticidade Máximo da Fibra

$E_{m_{max}}$ - Módulo de Elasticidade Máximo da Matriz

$E_{2_{max}}$ - Módulo de Elasticidade Transversal Máximo

$E_{f_{min}}$ - Módulo de Elasticidade Mínimo da Fibra

$E_{m_{min}}$ - Módulo de Elasticidade Mínimo da Matriz

$E_{2_{min}}$ - Módulo de Elasticidade Transversal Mínimo

$E_{f_{nor}}$ - Módulo de Elasticidade Normalizado da Fibra

$E_{m_{nor}}$ - Módulo de Elasticidade Normalizado da Matriz

$E_{2_{nor}}$ - Módulo de Elasticidade Transversal Normalizado

$E_{2_{real}}$ - Módulo de Elasticidade Transversal obtido Experimentalmente

$E_{2_{rna}}$ - Módulo de Elasticidade Transversal da Rede Neural Artificial

$E_{2_{estimado}}$ - Módulo de Elasticidade Transversal obtido pelas Equações de Halpin-Tsai

ΔW - Variação dos Pesos Sinápticos

ζ - Parâmetro Geométrico

Lista de Abreviações

RN Rede Neural

RNA Rede Neural Artificial

EMQ Erro Médio Quadrático

MLP *Multilayer Perceptron* (Perceptron Multicamadas)

RPROP Resilient Backpropagation

Lista de Figuras

Fig.2.1	Exemplo de Compósito de Múltiplas Camadas.	8
Fig.2.2	Formas possíveis de utilização de fibras na fabricação de materiais compósitos.	9
Fig.2.3	Diagrama das classificações das fibras naturais de origem vegetal.	10
Fig.2.4	Constituição estrutural de uma fibra vegetal.	11
Fig.2.5	Exemplos de matrizes poliméricas termoplásticas e termoendurecíveis.	12
Fig.2.6	Lâmina unidirecional com as direções principais indicadas pelos eixos 1, 2 e 3.	14
Fig.2.7	Rompimento da fibra de vidro em compósito polimérico.	16
Fig.2.8	Rompimento característico da fibra natural em compósito polimérico	17
Fig.2.9	Diversos exemplos de danos.	17
Fig.2.10	Modelo de primeira ordem de uma lâmina unidirecional.	18
Fig.3.1	Neurônio Biológico.	22
Fig.3.2	Modelo de um neurônio.	23
Fig.3.3	Função Sigmoide.	24
Fig.3.4	Função Tangente Hiperbólica.	24
Fig.3.5	Rede perceptron de múltiplas camadas.	25
Fig.3.6	Diagrama esquemático demonstrando o processo de aprendizado de uma rede neural, aonde (a) é o método de treinamento da RNA e (b) é o modelo obtido pelo treinamento da RNA.	27
Fig.3.7	Retropropagação em redes profundas.	28
Fig.3.8	Rede Perceptron de T camadas.	29
Fig.4.1	Mapa mental da arquitetura da RNA.	32
Fig.4.2	Mapa mental da arquitetura da RNA Híbrida.	33
Fig.4.3	Erro de predição por complexidade do modelo.	38
Fig.4.4	Validação cruzada por k-fold.	39
Fig.4.5	Arquitetura da rede neural com duas entradas.	40
Fig.4.6	Arquitetura de treinamento para RNA duas entradas.	41
Fig.4.7	Arquitetura da rede neural com três entradas.	41

Fig.4.8	Arquitetura de treinamento para RNA três entradas.	42
Fig.4.9	Arquitetura de treinamento e fluxograma da RNA de três entradas com Halphin-Tsai.	43
Fig.5.1	Análise do EMQ pelo número de épocas de treinamento da RNA de Duas Entradas.	45
Fig.5.2	Gráfico comparativo da RNA de Duas Entradas.	45
Fig.5.3	Análise do EMQ pelo número de épocas de treinamento da RNA de Três Entradas.	46
Fig.5.4	Gráfico comparativo da RNA de Três Entradas.	47
Fig.5.5	Análise do EMQ pelo número de épocas de treinamento da RNA modelo Híbrido.	48
Fig.5.6	Gráfico comparativo da RNA modelo Híbrido.	48
Fig.5.7	Gráfico de barras para análise do EMQ	49

Lista de Tabelas

Tbl. 2.1 Teores dos constituintes químicos de algumas fibras naturais de origem vegetal.	12
Tbl. 4.1 Valores coletados da literatura do módulo de elasticidade transversal para fibra.	35
Tbl. 4.2 Valores coletados da literatura do módulo de elasticidade transversal para matriz.	35
Tbl. 4.3 Valores do módulo de elasticidade transversal de compósitos unidirecionais.	35
Tbl. 5.1 Comparativo dos modelos de RNA com o modelo de Halpin-Tsai.	49

Sumário

1	Introdução	1
1.1	Problema de Pesquisa	2
1.2	Objetivos	3
1.3	Específicos	3
1.4	Justificativa	3
1.5	Motivação	4
1.6	Questões e hipóteses	5
1.7	Delimitação do estudo	5
1.8	Relevância do estudo	6
2	Materiais Compósitos	7
2.1	Classificação dos Materiais Compósitos	7
2.2	Fibras naturais	9
2.3	Matriz	12
2.4	Laminados de Compósitos Unidirecionais	13
2.5	Frações de Massa e Volume de uma Lâmina	14
2.6	Mecanismos de Dano	15
2.7	Análise da Micromecânica do Módulo de Elasticidade Transversal	18
3	Rede Neural Artificial	21
3.1	Neurônios Biológicos	22
3.2	Neurônios da RNA	23
3.3	Tipos de Arquitetura de Rede Neural	25
3.4	Treinamento de uma Rede Neural	26
4	Modelagem	32
4.1	Pré-processamento dos Dados	34
4.2	Modelo RNA de Duas Entradas	40
4.3	Modelo RNA de Três Entradas	41
4.4	Modelo híbrido RNA de três Entradas	42

5 Resultados	44
5.1 RNA de Duas Entradas	44
5.2 RNA de Três Entradas	46
5.3 Modelo Híbrido RNA de Três Entradas.	47
5.4 Análise Comparativa	49
6 Conclusão	50
Referências Bibliográficas	52

Introdução

No campo da engenharia mecânica a necessidade do aperfeiçoamento de materiais com propriedades que buscam alternativas para reduzir o impacto ambiental são cada vez mais imprescindíveis, sendo, com essas capazes de atender a estas novas exigências em termos de aplicação industrial.

Nesse sentido, a incorporação de fibras naturais em compósitos unidirecionais tem ganhado destaque, oferecendo não apenas uma alternativa sustentável, mas também melhorando certas propriedades, como resistência à tração e rigidez, em comparação com os compósitos convencionais feitos apenas com fibras sintéticas. Essa abordagem tem mostrado potencial para atender às demandas da indústria, oferecendo soluções mais ecologicamente sustentáveis.

Além disso, os compósitos unidirecionais se destacam como uma classe de materiais capazes de atingir tais objetivos, e têm sido amplamente utilizados nas indústrias devido à sua capacidade de satisfazer essas necessidades. Esses materiais possuem propriedades mecânicas complexas, tendo um investimento que pode não atender o custo/benefício do experimento necessário para obter as informações desejadas (Lorandi, Cioffi, & Ornaghi Jr, 2016).

No entanto, essas propriedades mecânicas são essenciais para a análise de falhas e para projetos de componentes estruturais. Assim, diversos modelos matemáticos foram propostos com o intuito de descrever o comportamento mecânico desses materiais, reduzir a quantidade de ensaios necessários, prever resultados e, conseqüentemente, diminuir os custos de projeto (Callister & Rethwisch, 2020).

Os modelos matemáticos utilizados para analisar o comportamento mecânico dos compósitos unidirecionais a partir de seus componentes são conhecidos como modelos micromecânicos. Esses modelos buscam, por meio de fórmulas estabelecidas, obter as propriedades do compósito com base nas propriedades individuais de seus componentes e nas frações volumétricas de cada um desses elementos (Vasiliev & Morozov, 2001).



Na literatura, existem diversos modelos matemáticos, empíricos e semi-empíricos, que são utilizados para estimar as propriedades elásticas de materiais compósitos a partir das propriedades individuais de seus componentes.

Sendo o mais simples deles conhecido como “regra das misturas”. Um dos modelos amplamente utilizados atualmente é denominado modelo de Halpin-Tsai (Vasiliev & Morozov, 2001). Esses modelos têm o objetivo de fornecer uma abordagem simplificada para a previsão das propriedades elásticas, levando em consideração fatores como a fração volumétrica dos componentes, suas propriedades intrínsecas e as interações entre os mesmos.

A Rede Neural Artificial (RNA) é uma ferramenta computacional recente que está sendo amplamente adotada em várias áreas da engenharia, incluindo a engenharia mecânica. Essas redes são inspiradas no funcionamento do cérebro humano e baseiam-se em uma modelagem matemática que permite o aprendizado computacional por meio de um conjunto de dados pré-estabelecidos, adquirindo conhecimento por meio da experiência em treinamentos computacionais (Haykin, 2001).

Essas unidades básicas chamadas neurônios ou processadores são interligadas, formando uma complexa rede de conexões, daí o nome “redes neurais”. Essa estrutura em rede possibilita a realização de uma ampla gama de tarefas, sendo especialmente eficaz como um aproximador universal de funções (Júnior, Neto, & de Aquino, 2005).

Na área dos materiais compósitos, as redes neurais já estão sendo aplicadas e apresentam resultados promissores.

1.1 Problema de Pesquisa

Os experimentos laboratoriais destinados a investigar o comportamento mecânico de materiais compósitos unidirecionais com fibras naturais enfrentam desafios significativos, decorrentes do baixo nível isotrópico e da alta capacidade hidrofílica das fibras naturais, além das complexidades na interface entre a fibra e a matriz.

Como antecipar o comportamento mecânico de materiais compósitos unidirecionais com fibras naturais, considerando os desafios associados ao baixo nível isotrópico e à alta capacidade hidrofílica das fibras, bem como as complexidades na interface fibra-matriz?

1.2 Objetivos

Geral

Aplicar modelos de RNA para a análise das propriedades de um compósito unidirecional reforçado com fibras naturais, assim sendo, capaz de fornecer os valores teóricos das propriedades mecânicas como o módulo de elasticidade transversal do compósito. E ainda, com esses valores obtidos, estabelecer uma relação com o modelo de Halpin-Tsai, através do coeficiente de correlação (r) e o Erro Médio Quadrático (EMQ).

1.3 Específicos

- Construir um modelo do módulo de elasticidade transversal com base no estudo do comportamento mecânico de materiais compósitos estruturais unidirecionais reforçados com fibras naturais utilizando três arquiteturas distintas;
- Aplicar análises de modelos analíticos às propriedades mecânicas, com ênfase no modelo de Halpin-Tsai;
- Avaliar os resultados obtidos pelos modelos analisados e pela RNA, de forma a validar a utilização do algoritmo. A análise comparativa será feita de forma qualitativa, através de gráficos, e quantitativa, através do EMQ e o coeficiente de correlação (r);

1.4 Justificativa

A crescente demanda por inovações na engenharia mecânica e o aprimoramento constante de materiais compósitos unidirecionais exigem abordagens eficientes para prever propriedades mecânicas de maneira precisa e econômica. Nesse contexto, o uso de RNA surge como uma estratégia promissora, aproveitando a capacidade desses modelos em aprender padrões complexos a partir de conjuntos de dados (Diniz et al., 2016).

A necessidade de prever propriedades mecânicas em compósitos unidirecionais impulsiona o uso de RNA, que oferecem precisão e eficiência mesmo em cenários complexos. Além disso, a integração de fibras naturais promove sustentabilidade ambiental na indústria de materiais compósitos.

Os compósitos unidirecionais apresentam desafios específicos, como a necessidade de predição de propriedades mecânicas complexas, incluindo o módulo de elasticidade transversal (E_2), em cenários onde métodos tradicionais podem ser dispendiosos e demandar uma quantidade significativa de ensaios experimentais. A RNA, ao simular o aprendizado humano,

oferecem a vantagem de generalização e capacidade de predição, mesmo em situações onde as relações entre variáveis são intrincadas (Watt, Davies, & O'Connell, 1976).

A aplicação de RNA na micromecânica dos compósitos unidirecionais proporciona uma oportunidade de avanço na modelagem computacional, permitindo a simplificação de processos e a redução da dependência de modelos tradicionais, como a regra das misturas e o modelo de Halpin-Tsai. Além disso, a flexibilidade inerente às RNA possibilita a exploração de diferentes arquiteturas e algoritmos de treinamento, adaptando-se às especificidades dos compósitos unidirecionais (Goleman, 2017).

1.5 Motivação

A utilização de fibras naturais em compósitos unidirecionais não apenas apresenta benefícios mecânicos, mas também traz considerações significativas do ponto de vista ecológico. As fibras naturais são recursos renováveis, biodegradáveis e geralmente têm um menor impacto ambiental em comparação com as fibras sintéticas tradicionais (Romão, 2003).

A necessidade de antecipar o comportamento mecânico desses materiais, como o módulo de elasticidade transversal (E_2), é crucial para otimizar projetos e processos industriais. A dificuldade reside não apenas na diversidade e especificidade das propriedades mecânicas, mas também na alta demanda de recursos associada à experimentação tradicional.

A abordagem da Rede Neural (RN) oferece uma perspectiva promissora, inspirada no aprendizado humano, para superar esses desafios. A capacidade desses modelos em aprender padrões a partir de dados complexos possibilita uma predição mais precisa, reduzindo a dependência de uma abordagem puramente experimental. Ao simularem o processo cognitivo, a RNA pode capturar relações não lineares e complexas, oferecendo uma alternativa valiosa para a modelagem de compósitos unidirecionais.

A flexibilidade da RNA, aliada à sua capacidade de generalização, oferece uma oportunidade única de otimizar a análise de compósitos unidirecionais, alinhando-se com as demandas crescentes por métodos mais ágeis e eficazes na engenharia mecânica moderna.

Portanto, ao incluir compósitos unidirecionais reforçados com fibras naturais, não apenas se avança na eficiência e precisão da engenharia mecânica, mas também se contribui para a mitigação dos impactos ambientais e para a promoção de práticas mais sustentáveis na indústria.

1.6 Questões e hipóteses

Com base na RNA responsável pela predição do módulo de elasticidade transversal de compósitos unidirecionais reforçados com fibras naturais, pode-se levantar algumas questões:

- Como a RNA pode ser aplicada para prever o comportamento mecânico de compósitos unidirecionais com fibras naturais, superando os desafios relacionados ao baixo nível isotrópico e alta capacidade hidrofílica dessas fibras?
- Quais são as características específicas das arquiteturas neurais que melhor se adaptam à análise de compósitos unidirecionais, considerando a simplificação do modelo através de um número reduzido de parâmetros de entrada?

Para embasar uma argumentação sobre estas questões, são delimitadas as seguintes hipóteses:

- A utilização de RNA, devidamente treinadas, pode superar as dificuldades relacionadas ao baixo nível isotrópico e alta capacidade hidrofílica de fibras naturais, proporcionando uma predição mais precisa do comportamento mecânico de compósitos unidirecionais;
- Arquiteturas neurais simplificadas, que buscam a adaptação aos princípios micromecânicos, com um número reduzido de parâmetros de entrada, apresentarão desempenho satisfatório na predição de propriedades mecânicas, equivalente aos modelos convencionais, como o modelo de Halpin-Tsai;

1.7 Delimitação do estudo

Este estudo estará restrito à aplicação de RNA na predição do módulo de elasticidade transversal (E_2) em compósitos unidirecionais. A delimitação inclui a análise específica desses materiais, considerando sua orientação unidirecional das fibras, e a ênfase estará nas propriedades mecânicas. A delimitação exclui outros tipos de materiais, como compósitos bidirecionais, multidirecional e de orientação aleatória. A avaliação comparativa será realizada quantitativamente, utilizando métricas como EMQ e o coeficiente de correlação (r), quanto qualitativamente, através de gráficos. Este estudo concentra-se na aplicação prática da RNA na engenharia mecânica, especificamente para prever propriedades mecânicas em compósitos unidirecionais.

1.8 Relevância do estudo

Esse estudo busca explorar e aprimorar métodos de predição de propriedades mecânicas em compósitos unidirecionais, com o objetivo de simplificar esses processos, permitindo uma predição mais precisa e econômica do módulo de elasticidade transversal (E_2) através do uso de RN. Além disso, ao considerar compósitos unidirecionais reforçados com fibras naturais, o estudo expande a aplicabilidade das técnicas desenvolvidas para materiais mais sustentáveis e de menor impacto ambiental.

A redução de custos experimentais é uma consideração significativa, já que o estudo propõe uma alternativa eficiente à abordagem tradicional, diminuindo a necessidade de ensaios experimentais, especialmente em cenários onde métodos convencionais podem ser economicamente inviáveis. Ao incorporar compósitos unidirecionais reforçados com fibras naturais, a pesquisa também pode contribuir para a redução de custos associados à aquisição e processamento de materiais, promovendo práticas mais sustentáveis e economicamente viáveis.

Essa abordagem tem o potencial de gerar conhecimentos diretamente aplicáveis em projetos estruturais, enquanto promove a adoção de materiais mais sustentáveis na indústria.

O potencial para generalização é uma dimensão estratégica, uma vez que os resultados obtidos não se limitam apenas aos compósitos unidirecionais, podendo ser estendidos para uma aplicação mais ampla de RNA em outros contextos na engenharia de materiais.

Materiais Compósitos

Materiais compósitos são materiais feitos combinando dois ou mais componentes com propriedades diferentes, geralmente um material matriz e um material de reforço. Essa combinação resulta em um material que possui propriedades superiores às dos materiais individuais, tornando-os amplamente utilizados em várias indústrias, incluindo aeroespacial, automotiva, construção, esportes e eletrônicos, entre outras (Callister & Rethwisch, 2020).

Eles possuem propriedades que dificilmente poderiam ser alcançadas por materiais convencionais, sendo compostos por metais, cerâmicas e polímeros. Essa diversidade de materiais permite atingir níveis de desempenho que nenhum material individual poderia oferecer, tornando-os ideais para atender às demandas dessas aplicações mencionadas.

2.1 Classificação dos Materiais Compósitos

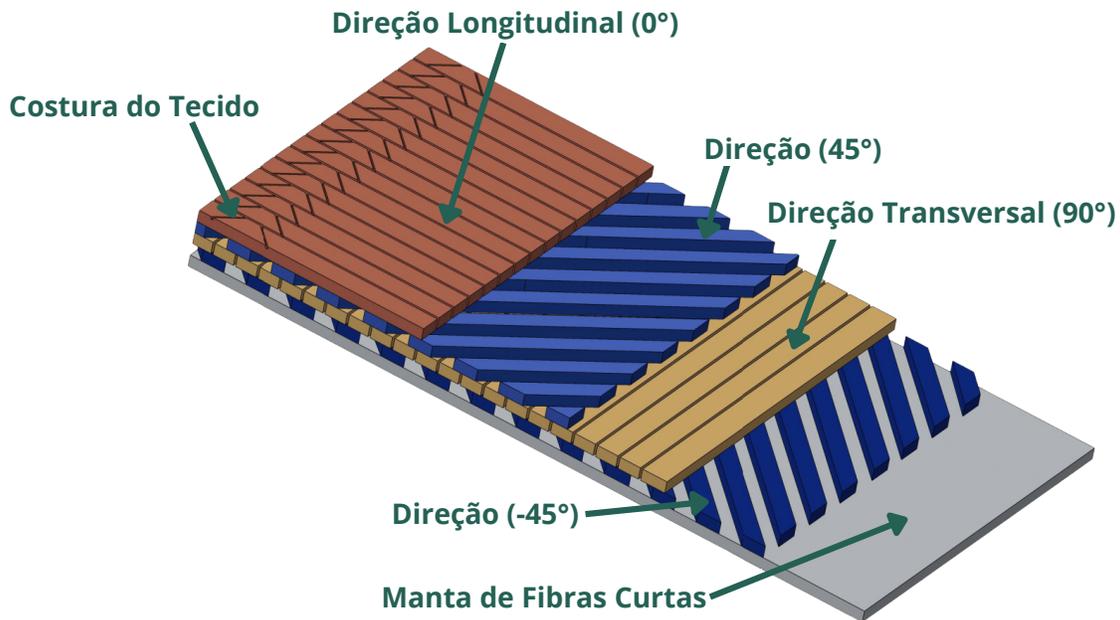
Os materiais compósitos possuem características bem distintas dos demais tipos de materiais, sendo essas características correlacionadas à sua composição, orientação das fibras de reforço e a sua geometria (Callister & Rethwisch, 2020).

Os reforços são os componentes que conferem maior resistência aos compósitos. Eles são geralmente denominados como a fase dispersa e desempenham um papel fundamental no transporte da carga nos materiais compostos, proporcionando maior resistência, módulo e elasticidade. As fibras sintéticas são o tipo de reforço mais comum e, em sua maioria, são produzidas a partir de resinas derivadas do petróleo. Algumas das principais fibras utilizadas como reforço em materiais compósitos são: carbono, polietileno, polipropileno, vidro, náilon e aramida (Oliveira, 2018).

Os materiais microcompósitos são subdivididos em quatro categorias: materiais compósitos fibrosos, materiais compósitos particulados, materiais compósitos laminados e materiais compósitos híbridos. No entanto, para os propósitos deste trabalho, somente os materiais compósitos fibrosos são pertinentes.

Na Figura 2.1, pode ser visualizado um exemplo de compósito multicamadas com múltiplas orientações das fibras de reforço.

Figura 2.1: Exemplo de Compósito de Múltiplas Camadas.



Fonte: Elaborado pelo autor (2024).

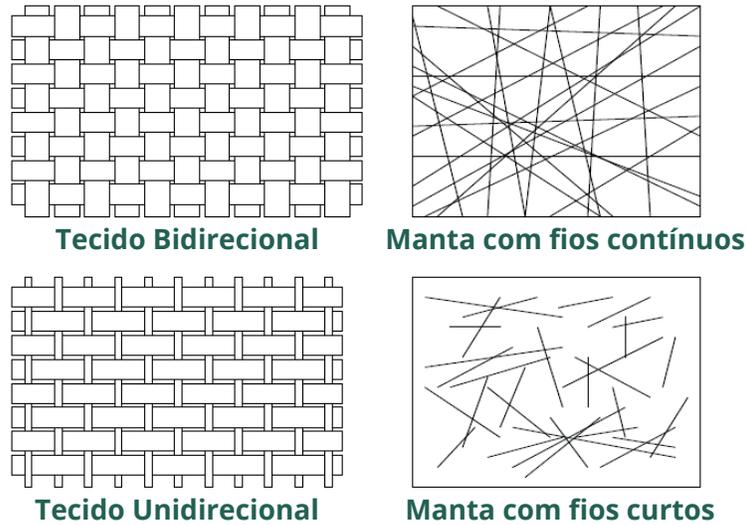
Materiais Compósitos Fibrosos

O reforço fibroso de um material compósito consiste em milhares de filamentos individuais com diâmetros muito pequenos da ordem de micrómetros, dispersados na matriz polimérica. Tipicamente as propriedades mecânicas das fibras são de uma magnitude muito superiores às do polímero que elas reforçam (Bank, 2006).

Para além destes requisitos, exigidos às matrizes, também as fibras devem apresentar características que permitam reforçar os polímeros de uma forma eficaz (Romão, 2003).

Para além dos requisitos acima referidos, existem outros factores, relacionados com a natureza do reforço que influenciam as propriedades finais de um compósito. A quantidade de fibras, a sua orientação e o seu comprimento são características que influenciam de forma preponderante as características dos polímeros reforçados com fibras, de tal forma que os compósitos podem ser classificados segundo o esquema da Figura 2.2.

Figura 2.2: Formas possíveis de utilização de fibras na fabricação de materiais compósitos.



Fonte: Adaptado de Kaw (2005).

2.2 Fibras naturais

Desde o surgimento da humanidade, as fibras naturais são utilizadas para melhorar as propriedades dos materiais. Como exemplo das primeiras fibras de origem natural utilizadas, o linho possui mais de 8 mil anos de história, obteve seu nascimento no Egito, as margens do Nilo, e na Crimeia, como confirmamos achados arqueológicos. O algodão também é um exemplo de fibra natural muito antiga. A época em que o homem começou a cultivar o algodão com fins têxteis ainda é incerta. Na Índia pode-se encontrar vestígios dessa fibra tecida que datam de 3200 a.C., além de sinais de remotas plantações de algodão (Pezzolo, 2019).

No Brasil, podem ser citadas diferentes tipos de fibras, que possuem distinções em suas propriedades, mecânicas, químicas e física.

Fibras naturais como as de algodão, sisal, juta, cânhamo, ou linho são de natureza renovável, mais baratas, e têm um menor impacto ambiental, uma vez que são biodegradáveis. A substituição de peças reforçadas com fibras sintéticas pelas reforçadas com fibras naturais é muito recomendável, pois reduzem os possíveis impactos ambientais intrínsecos aos materiais sintéticos (Romão, 2003).

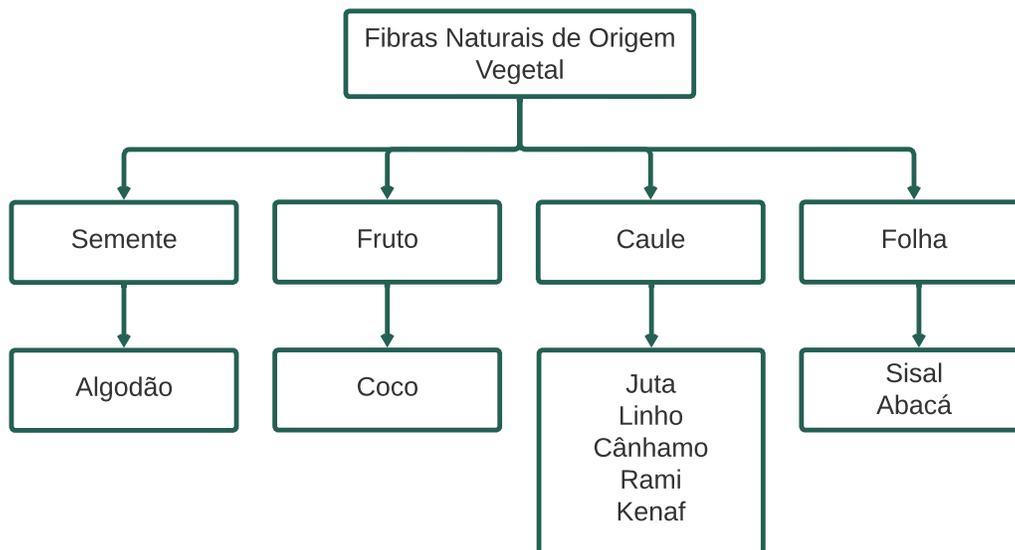
Alguns benefícios que podem ser observados com o uso incluem baixa condutividade térmica, alta resistência elétrica e a capacidade de ampliar a difusão, tornando-o adequado como material acústico. Além disso, o menor peso de compósitos reforçados com fibras naturais melhora a eficiência de combustível. Comparado a outras fibras sintéticas, ele possui uma baixa densidade específica e oferece uma boa relação custo-benefício (Schelb, 2016).

Entretanto, existem também possíveis limitações decorrentes da utilização de fibras naturais como reforço de materiais poliméricos, como exemplo, possuem baixa resistência à temperatura, alta afinidade hidrofílica, e falta de interface entre as fibras e as matrizes. A maior problemática relacionada às fibras naturais se deve aos grupamentos hidrofílicos presentes em sua estrutura química. Esses grupos conferem às fibras naturais uma propriedade polar, enquanto os polímeros olefínicos são apolares.

Classificação das Fibras Naturais de Origem Vegetal.

As fibras naturais são subdivididas de acordo com sua origem: vegetal, animal ou mineral. Devido as suas propriedades, as fibras de origem vegetal têm maior potencial na engenharia, como pode ser visualizada na Figura 2.3.

Figura 2.3: Diagrama das classificações das fibras naturais de origem vegetal.



Fonte: Adaptado de Faruk, Bledzki, Fink, and Sain (2012).

Por exemplo, as fibras de origem animal apresentam menor resistência e maior alongamento em relação às fibras vegetais, enquanto as fibras minerais possuem maior valor de compra, são mais quebradiças e carecem de resistência e flexibilidade (Castro, 2013).

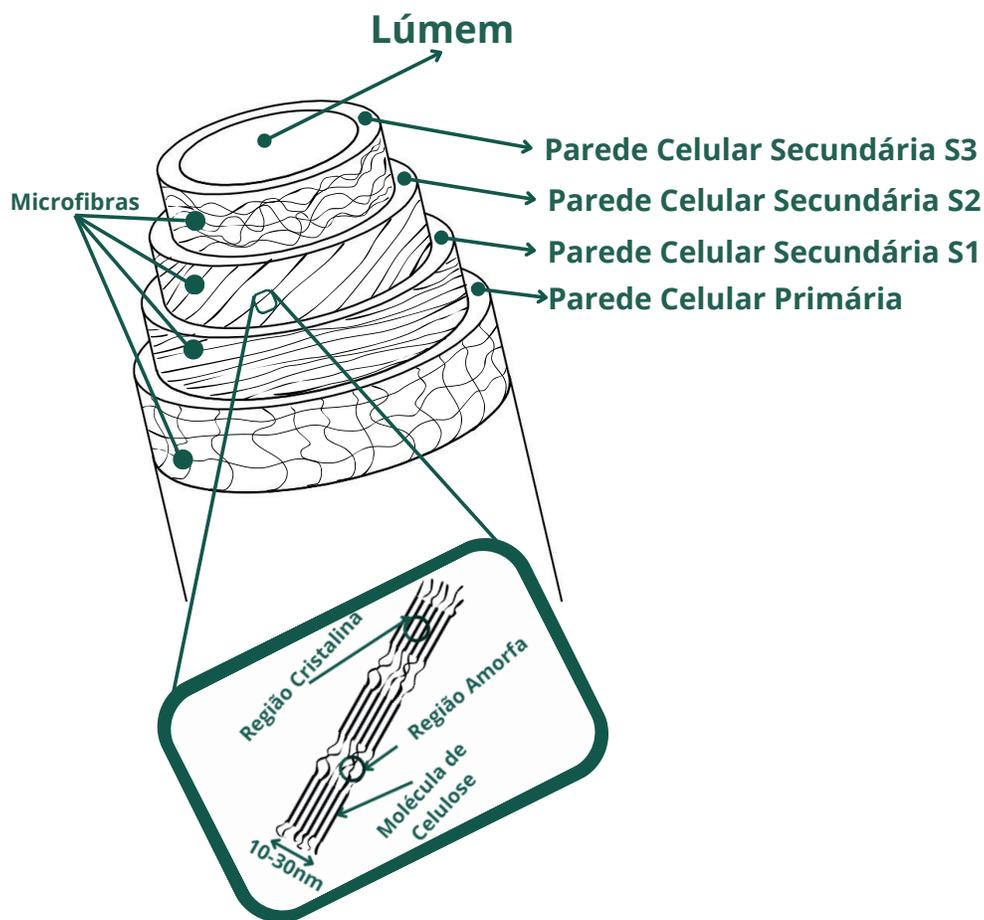
Estrutura e Constituintes das Fibras Naturais de origem vegetal.

As características das mesmas dependem das propriedades dos constituintes individuais, da estrutura fibrilar e da matriz lamelar. A fibra é composta por numerosas células de fibra fusiforme alongadas que se afunilam em direção a cada extremidade. Portanto, todas as fibras vegetais são de natureza hidrofílica; seu teor de umidade atinge 8-13% (Castro, 2013).

As fibras naturais de origem vegetal contêm diferentes substâncias naturais. O mais importante deles é a lignina. As células distintas das fibras vegetais duras são unidas pela lignina, a mesma atua como um material cimentante. O teor de lignina das fibras vegetais influencia sua estrutura, propriedades e morfologia (Araújo, 2019).

Consideradas como compósitos de ocorrência natural, são compostas principalmente de fibrilas de celulose embebidas em matriz de lignina. Estas fibrilas de celulose estão alinhadas ao longo do comprimento da fibra. Parece que tal alinhamento proporciona máxima resistência à tração e flexão, além de proporcionar rigidez nessa direção da fibra, como pode ser visualizada na Figura 2.4 (Nascimento, Silva, Dias, Gomes, & Fujiyama, 2019).

Figura 2.4: Constituição estrutural de uma fibra vegetal.



Fonte: Adaptado de Eichhorn, Hearle, Jaffe, and Kikutani (2009).

Para cada tipo de fibra natural, é apresentada a percentagem dos quatro principais constituintes químicos, como pode ser verificado na Tabela 2.1.

Tabela 2.1: Teores dos constituintes químicos de algumas fibras naturais de origem vegetal.

Origem	Fibras	Celulose (%)	Hemicelulose (%)	Lignina (%)	Pectina (%)
Semente	Algodão	82-96	2-6,4	0-5	<1-7
Fruto	Coco	43-46	0,25	45-46	3-4
Caule	Juta	51-84	12-20	5-13	0,2
Caule	Linho	60-81	14-20,6	2,2-5	1-4
Caule	Cânhamo	70-92	18-22	3-5	1
Caule	Rami	68-76	13-15	0,6-1	2
Caule	Kenaf	44-87	22	15-19	2
Folha	Sisal	43-78	10-24	4-12	0,8-2
Folha	Abacá	61-64	21	12	0,8

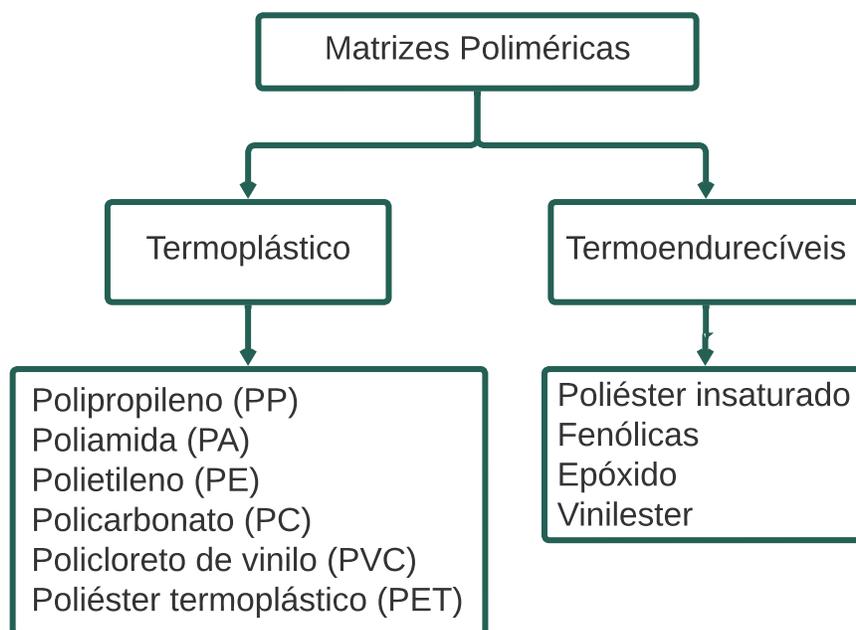
Fonte: Mwaikambo (2006).

2.3 Matriz

A matriz empregada na fabricação de materiais compósitos tem como objetivo transferir as cargas mecânicas para o reforço, conferindo ductilidade à sua estrutura e coesão. Ao envolver o material de reforço, proporciona flexibilidade ao compósito, ao mesmo tempo que o protege contra as influências do ambiente externo (A. P. d. O. Silva, Quaresma, Motta, & Francklin, 2015).

Os tipos mais comuns de matrizes são: metálicas, cerâmicas e poliméricas, sendo as poliméricas as mais utilizadas em compósitos. Elas podem ser divididas em termoplásticas e termoendurecíveis, como pode visualizado na Figura 2.5.

Figura 2.5: Exemplos de matrizes poliméricas termoplásticas e termoendurecíveis.



Fonte: Adaptado de Castro (2013).

Os termoplásticos são compostos por macromoléculas unidas por forças relativamente fracas, como as forças de Van der Waals. Quando aquecidos, tornam-se flexíveis devido à quebra das ligações intermoleculares, alcançando um estado líquido viscoso acima da temperatura de transição vítrea. Essa temperatura é definida como a média da faixa de temperatura entre a linha base quando o material está rígido e a linha base quando está amolecido, também conhecido como estado borrachoso (Passatore, 2013).

Os termoplásticos incluem o polietileno, o cloreto de polivinila, o poliestireno, a poliamida, o acetato de celulose, o policarbonato e o polipropileno. Eles têm a característica importante de retornar ao estado sólido quando resfriados, o que permite ciclos repetidos de aquecimento e resfriamento, sendo utilizados em diversos processos de fabricação (Cavalcante, 2018).

Por outro lado, os termorrígidos, ao contrário dos termoplásticos, não podem ser refundidos e conformados repetidamente, devido à forte ligação covalente entre as cadeias. Sua produção ocorre por meio de uma reação química em dois estágios. O primeiro estágio resulta na formação de moléculas de cadeias longas semelhantes às dos termoplásticos, mas ainda reativas (Vasconcelos, 2013).

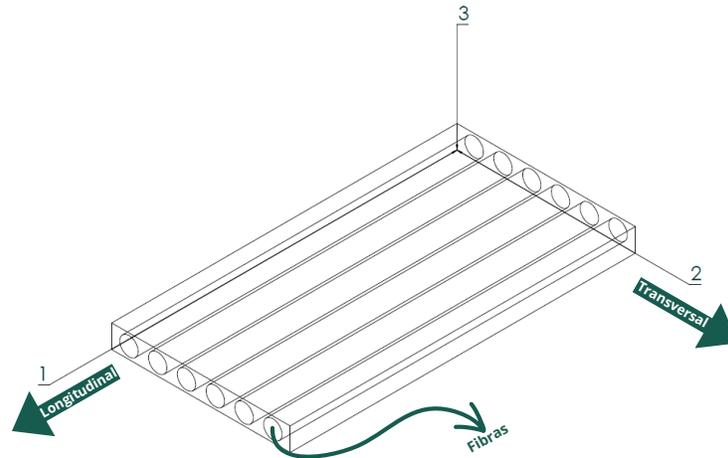
No segundo estágio da reação, ocorre a formação de ligações cruzadas entre as cadeias formadas no primeiro estágio, geralmente por meio da adição de agentes de cura e da aplicação de calor e/ou pressão (Godoy, 2019).

2.4 Laminados de Compósitos Unidirecionais

Os laminados compósitos unidirecionais são compostos por várias lâminas unidirecionais sobrepostas. Estes materiais consistem em dois elementos: a matriz e o reforço, sendo que o reforço é formado por fibras alinhadas em uma única direção. A complexidade do comportamento mecânico desses materiais é significativamente maior em comparação com outros materiais convencionais. Sua maior característica é o alinhamento das camadas de reforço, as quais devem estar todas orientadas em uma única direção, geralmente paralelas à carga longitudinal (Callister & Rethwisch, 2020).

Na Figura 2.6, são identificados os três eixos principais que determinam as propriedades mecânicas do material. A fase de reforço é composta por fios, cuja espessura de camada, mínima em compósitos modernos, é de cerca de 0,1 mm, muito maior que o diâmetro das fibras, que está na faixa de 0,01 mm. Tanto o reforço quanto a matriz têm suas quantidades especificadas em termos de frações de volume e massa (Vasiliev & Morozov, 2001).

Figura 2.6: Lâmina unidirecional com as direções principais indicadas pelos eixos 1, 2 e 3.



Fonte: Elaborado pelo autor (2024).

2.5 Frações de Massa e Volume de uma Lâmina

Nos materiais compósitos as quantidades de fibra e matriz são expressas em frações volumétricas e mássicas, assim sendo, expressas pelas equações 2.1 e 2.2:

$$V_f = \frac{V_f}{V_C} \quad V_m = \frac{V_m}{V_C} \quad V_v = \frac{V_v}{V_C} \quad (2.1)$$

Na Equação 2.1 se tem uma razão que prediz o valor da fração volumétrica dos componentes da lâmina, sendo o termo V o volume, onde os subíndices f , m , v e c , indicam os valores para fibra, matriz, vazios e compósito.

$$M_f = \frac{m_f}{m_C} \quad M_m = \frac{m_m}{m_C} \quad (2.2)$$

Da mesma maneira, a Equação 2.2 é uma razão que relaciona as massas (m_f, m_m) da fibra e matriz com a total m_c , do material composto, indicando suas frações mássicas M . Outra alternativa de se obter a fração mássica da fibra e matriz é através da densidade dos seus componentes, como pode visualizado na Equação 2.3 e 2.4:

$$V_f = \left(\frac{\rho_f}{\rho_c} \right) V_f \quad (2.3)$$

$$V_m = \left(\frac{\rho_m}{\rho_c} \right) V_m \quad (2.4)$$

2.6 Mecanismos de Dano

Os materiais compósitos podem apresentar uma variedade de danos antes de se romperem. Para descrever esses danos, observa-se três escalas: macroescala, que considera o comportamento geral do compósito laminado avaliado; mesoescala, que define a lâmina e a interface associada; e microescala, que considera a estrutura heterogênea (Oliveira, 2018).

Na microestrutura, que envolve a interação fibra/matriz, ocorre a fratura das fibras, podendo resultar na fratura da matriz, no deslocamento entre matriz e fibra e até mesmo na flambagem das fibras. Mecanicamente, os danos podem levar à ruptura da matriz ou da fibra, à delaminação e à ruptura transversal da lâmina ou do laminado, podendo ocorrer independentemente ou devido à interface fibra/matriz (Neto & Pardini, 2016).

Segundo Oliveira (2018), os principais tipos de danos em compósitos como fissuração na matriz, que é caracterizada por uma ou mais fissuras na matriz do material compósito, também conhecida como fratura coesiva na matriz; ruptura da fibra, que envolve a ruptura transversal e longitudinal da fibra, também chamada de fratura coesiva na fibra; e desaderência fibra/matriz, que consiste no deslocamento ou desprendimento na interface entre fibra e matriz, denominada fratura adesiva.

Os mecanismos de dano podem ser influenciados por diversos fatores, como as propriedades físicas e químicas dos reforços e da matriz, a configuração do compósito, o processo de fabricação, o tipo de carregamento, as características microestruturais e as condições ambientais (M. A. Leão, 2013).

A delaminação, que ocorre devido à separação das camadas devido à degradação da ligação adesiva, pode ser acelerada por fatores como a umidade, causando fissuras e desgaste em certos materiais. Esse processo é mais comum em compósitos laminados. As fraturas e danos podem ocorrer em diversos tipos de cargas, com a microflambagem restrita a cargas de compressão (Líbano, da Costa Pereira, Bastos, de Souza Coelho, et al., 2020).

No caso de fadiga em compósitos fibrosos, são considerados quatro estágios: nucleação do dano localizada pela carga cíclica, nucleação de microtrincas, propagação estável da trinca devido à carga cíclica e propagação local da trinca, dependente da orientação da fibra, ductilidade da matriz e adesão da interface. As tensões de compressão não promovem a propagação das trincas, enquanto as de tração são responsáveis por esse fenômeno (J. F. A. Leão, 2018).

O conjunto de estruturas e mecanismos de danos que ocorrem durante a carga de materiais compósitos não é completamente compreendido, havendo diversas teorias sobre o assunto, especialmente quando se trata de compósitos com fibras vegetais e seus derivados e feitos, como a absorção de umidade (Recicar, 2022).

Análise Macroscópica do Mecanismo de dano

A análise macroscópica dos mecanismos de danos nos materiais é crucial para entender sua integridade estrutural e seu desempenho ao longo do tempo. Existem pelo menos duas formas principais de danos: aqueles causados pelo tempo de uso, como o desgaste do material em ambientes agressivos, e aqueles originados pela aplicação de cargas externas, levando à fratura mecânica dos elementos estruturais (Felipe, 2012).

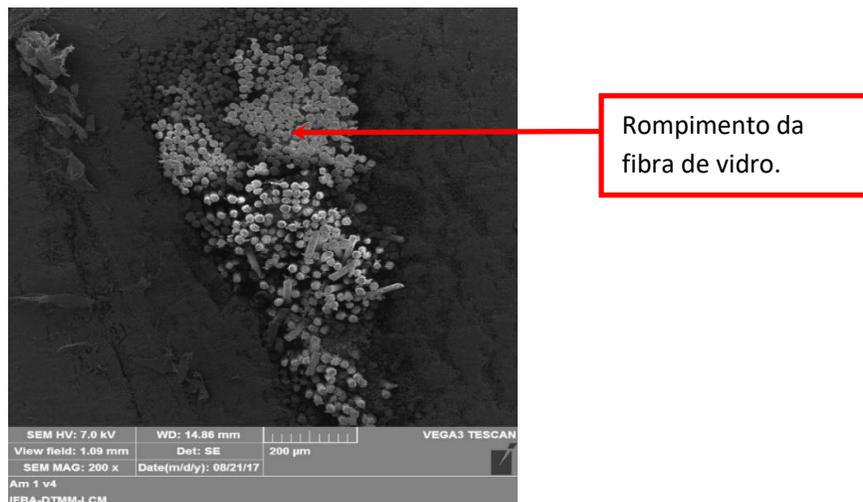
Nessa análise macroscópica, é possível observar características específicas de danos nos corpos de prova em ensaios mecânicos. Essas características podem incluir microfissuração na matriz do material, ruptura de fibras e até mesmo delaminação, que é caracterizada pela separação das interfaces em um laminado. Entender esses mecanismos de danos macroscópicos é fundamental para desenvolver estratégias de manutenção, reparo e otimização de materiais (Oliveira, 2018).

Análise Microscópica do Mecanismo de dano

A análise microscópica do mecanismo de dano é uma abordagem mais detalhada que permite investigar as causas fundamentais por trás das falhas nos materiais. Enquanto a análise macroscópica se concentra nos efeitos visíveis das falhas, como fraturas e desgaste, a análise microscópica busca compreender os processos que ocorrem em microestrutural (Felipe, 2012).

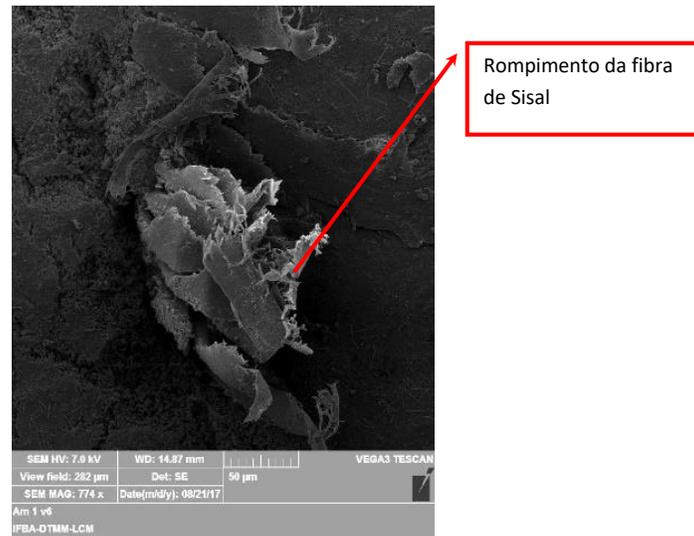
A Figura 2.7 representa a fratura coesiva da fibra sintética de vidro, enquanto a Figura 2.8 caracteriza a fratura coesiva da fibra natural de sisal.

Figura 2.7: Rompimento da fibra de vidro em compósito polimérico.



Fonte: Oliveira (2018).

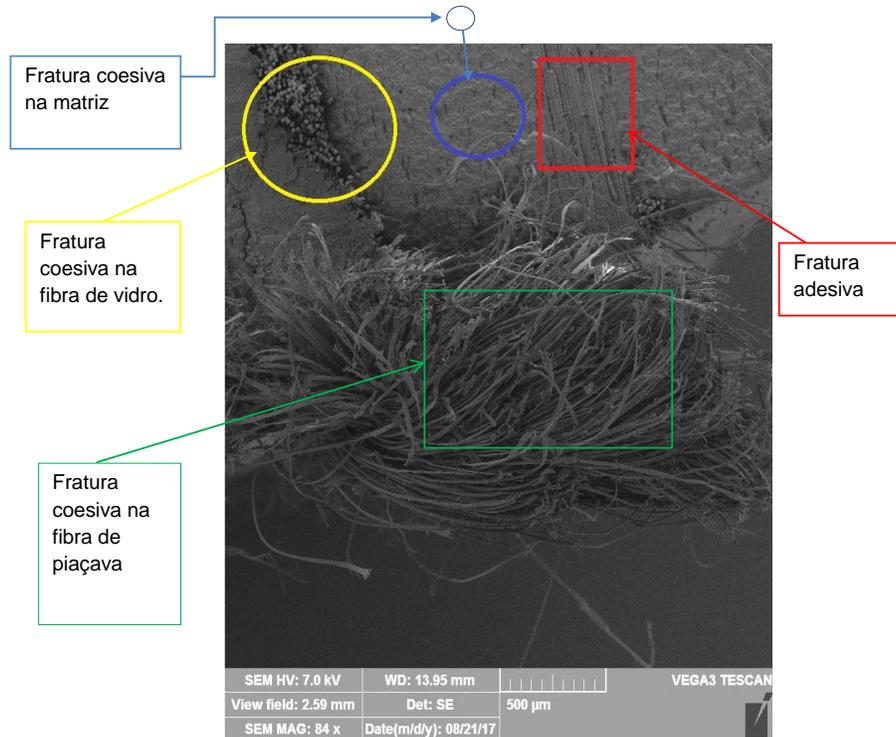
Figura 2.8: Rompimento característico da fibra natural em compósito polimérico



Fonte: Oliveira (2018).

A Figura 2.9 ilustra os danos observados nos compósitos poliméricos, fornecendo exemplos que corroboram a teoria discutida no referencial teórico sobre os mecanismos de danos na micrografia.

Figura 2.9: Diversos exemplos de danos.



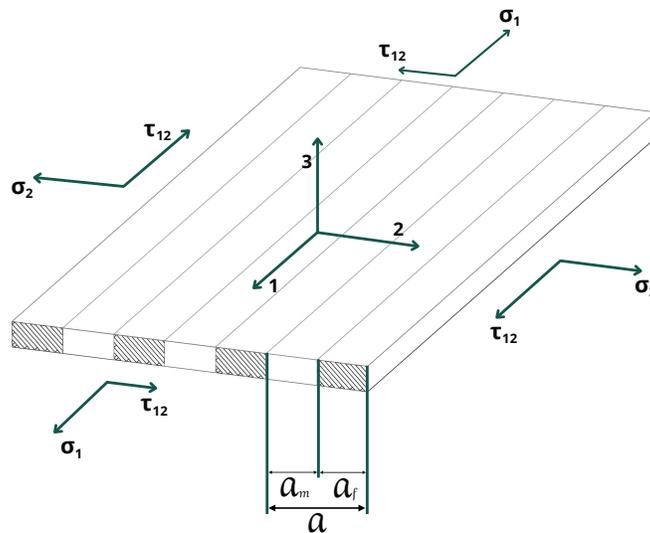
Fonte: Oliveira (2018).

2.7 Análise da Micromecânica do Módulo de Elasticidade Transversal

As equações desta abordagem foram em geral desenvolvidas a partir do ajuste de curvas com dados experimentais, sendo consideradas semi-empíricas pelo fato das variáveis envolvidas possuírem significado físico. Nesse contexto, deve-se também definir a geometria da seção-transversal da fibra analisada, pois algumas propriedades são avaliadas de forma distinta para fibras retangulares e circulares/quadradas (Kaw, 2005).

Regra das Misturas

Figura 2.10: Modelo de primeira ordem de uma lâmina unidirecional.



Fonte: Elaborado pelo autor (2024).

Na Figura 2.10, pode ser visto o modelo de regra das misturas, também chamado de modelo de primeira ordem, esse modelo requer as propriedades da fibra e matriz, assim como à fração volumétrica de fibras. O esquema desse modelo com a lâmina constituída de fibra e de matriz, com as respectivas tensões σ_1 , σ_2 e σ_{12} (de Mendonça, 2005).

Segundo Vasiliev and Morozov (2001), tem-se que a força resultante, que resulta no produto σ_{1a} , é distribuída entre as tiras de fibra e matriz, e a deformação longitudinal na direção 1 que é a mesma nessas tiras e na lâmina como um todo. Utilizando esse modelamento é possível obter algumas propriedades mecânicas dos materiais compósitos, como por exemplo os módulo de elasticidade longitudinal (E_1) e transversal (E_2), coeficiente de Poisson (ν_{12}) e o limite de resistência do compósito na direção longitudinal ($\sigma_{c,l}^*$).

As equações 2.5, 2.6, 2.7 e 2.8 mostram os modelos, respectivamente:

$$E_1 = E_2 V_f + E_2 V_f \quad (2.5)$$

$$\frac{1}{E_2} = \frac{V_f}{E_f} + \frac{V_m}{E_m} \quad (2.6)$$

$$E_2 = \frac{E_m E_f}{V_m E_f + V_f E_m}$$

$$\nu_{12} = \nu_f V_f + \nu_m V_m \quad (2.7)$$

$$\sigma_{c,l}^* = \sigma_f^* V_f + \sigma_m' (1 - V_f) \quad (2.8)$$

Outra propriedade importante, também obtida pela regra das misturas, é a tensão última à tração longitudinal (X_t), essa é definida pela Equação 2.9:

$$X_t = \sigma_{ult,f} \left[V_f \left(1 - \frac{E_m}{E_f} \right) + \frac{E_m}{E_f} \right] \quad (2.9)$$

Modelo de Halpin-Tsai

Um outro modelo bem mais utilizado para aplicação na área de projetos é o modelo proposto por Halpin and Tsai (1969). Por ser um modelo semiempírico o modelo se baseia em resultados experimentais, utilizando de parâmetros ajustados, mas também tem uma base na mecânica teórica.

A Equação 2.10 serve para representar as seguintes propriedades mecânicas: E_2 , G_{12} , ν_{23} através da variável P . O termo V_f representa a fração volumétrica de fibra no compósito unidirecional (Halpin & Tsai, 1969).

$$P = \frac{P_m(1 + \zeta \eta V_f)}{1 - \eta V_f} \quad (2.10)$$

O termo ζ é um parâmetro geométrico que mede o nível de reforço no compósito. Normalmente se usa $\zeta = 2$ para a análise de E_2 e $\zeta = 1$ para a análise de G_{12} , quando $\zeta = 0$ a equação de Halpin-Tsai se iguala a equação demonstrada para a regra das misturas (Affdl & Kardos, 1976).



Para o cálculo de E_2 por Halpin-Tsai é sugerido para ζ :

$\zeta = 2$ para fibra de seção circular,

$\zeta = 2a/b$ para fibra de seção retangular

A Equação 2.11 define o parâmetro η da Equação 2.10.

$$\eta = \frac{P_f/P_m - 1}{P_f/P_m + \xi} \quad (2.11)$$

Rede Neural Artificial

De acordo com Haykin (2001), pode-se definir uma rede neural como um processador massivamente paralelamente distribuído, sendo constituído de unidades de processamento simples, com uma propensão natural para armazenar conhecimento experimental e torna-lo disponível para o uso. Sendo assim, uma RNA se assemelha ao cérebro sob dois aspectos: o primeiro em que o conhecimento adquirido pela rede por meio de um processo de aprendizagem, e o segundo do qual as conexões entre os neurônios (pesos sinápticos) são utilizadas para armazenar o aprendizado.

A RN adquire conhecimento por meio de um processo de aprendizagem semelhante ao que o cérebro humano aprende com experiências e informações recebidas, uma RNA também pode aprender a partir de dados de treinamento. Através de algoritmos de aprendizagem, a rede é exposta a exemplos e padrões, ajustando os pesos sinápticos das conexões entre os neurônios para capturar e representar o conhecimento adquirido (Haykin, 2001).

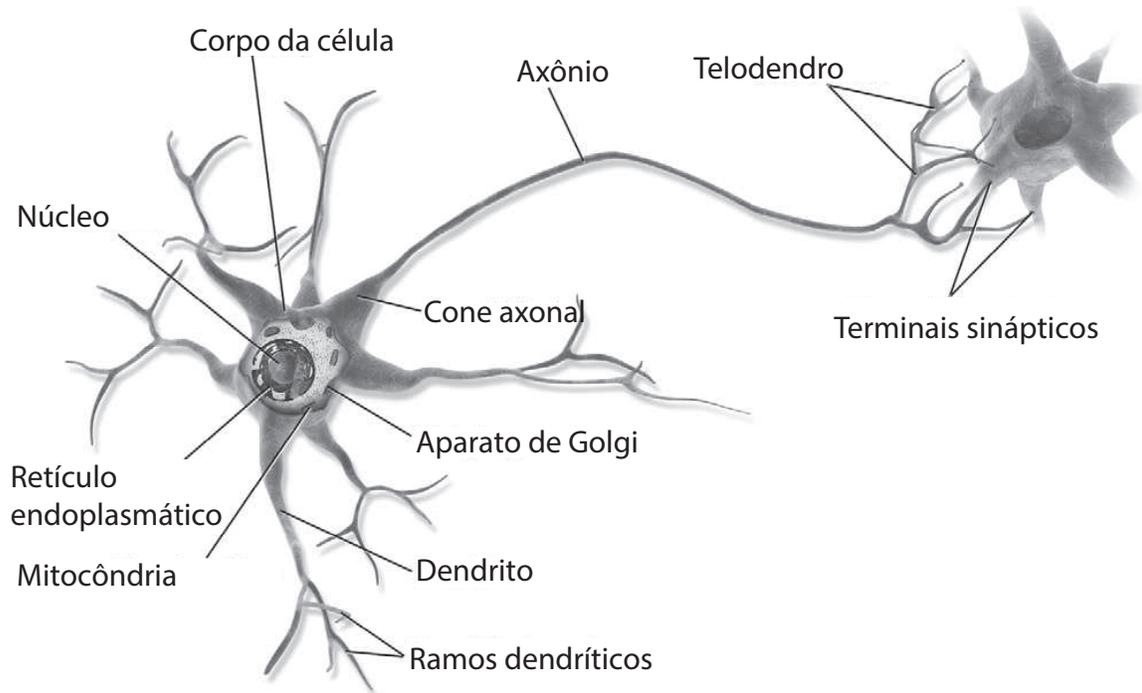
As conexões entre os neurônios, representadas pelos pesos sinápticos, são utilizadas para armazenar o aprendizado. Assim como as sinapses no cérebro humano se fortalecem ou enfraquecem com base na experiência e no aprendizado, as conexões entre os neurônios em uma RNA são ajustadas para refletir o conhecimento adquirido durante o treinamento. Esses pesos sinápticos codificam as relações e os padrões aprendidos pela rede, permitindo que ela generalize e tome decisões com base nas informações disponíveis (Freire Jr & Aquino, 2005).

Dessa forma, uma RNA se assemelha ao cérebro tanto no processo de aprendizagem quanto no armazenamento do conhecimento por meio das conexões sinápticas entre os neurônios. Essa semelhança possibilita que a RNA seja uma poderosa ferramenta para tarefas complexas de processamento de dados, como classificação, reconhecimento de padrões e tomada de decisões.

3.1 Neurônios Biológicos

Esse tipo de célula é encontrado principalmente no córtex cerebral de animais, como o cérebro humano. Ela consiste em um corpo celular que contém o núcleo e a maioria dos componentes complexos da célula, juntamente com várias extensões ramificadas chamadas dendritos, como pode ser visualizado na Figura 3.1 (M. Câmara, 2014).

Figura 3.1: Neurônio Biológico.



Fonte: Géron (2019).

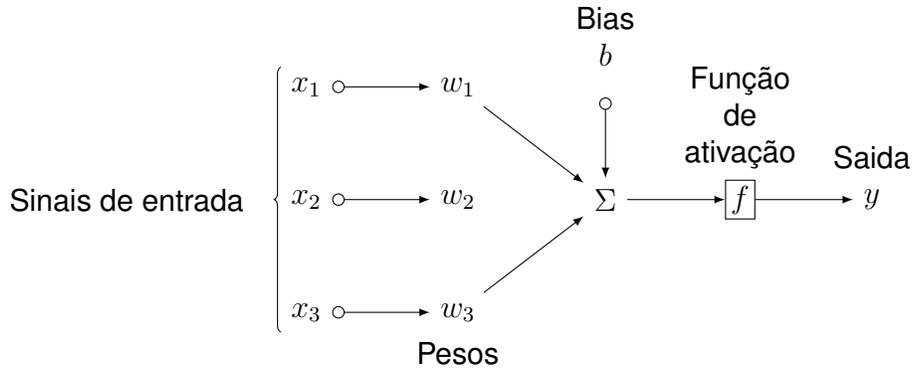
Além disso, há uma extensão muito longa chamada axônio, que pode ser apenas algumas vezes mais longa do que o corpo celular ou até mesmo dezenas de milhares de vezes maior (Shepherd, 2003).

De acordo com Shepherd (2003), próximo à sua extremidade, o axônio se divide em muitos ramos chamados telodendros, e nas pontas desses ramos encontram-se estruturas minúsculas conhecidas como terminais sinápticos, ou simplesmente sinapses, que se conectam aos dendritos de outros neurônios (ou diretamente ao corpo celular).

Os neurônios biológicos recebem breves impulsos elétricos de outros neurônios por meio dessas sinapses, chamados de sinais. Quando um neurônio recebe um número suficiente de sinais de outros neurônios em um curto espaço de tempo, ele dispara seus próprios sinais (M. Câmara, 2014).

3.2 Neurônios da RNA

Figura 3.2: Modelo de um neurônio.



Fonte: Adaptado de A. d. N. Silva (2017).

A célula fundamental de uma rede neural artificial é chamada de neurônio, assim como ocorre nas redes neurais cerebrais. A Figura 3.2 ilustra os componentes presentes dentro de um neurônio. Nele, podemos identificar sinapses, um componente de combinação linear e uma função ativadora (Freire Jr & Aquino, 2005).

Na rede neural artificial, as sinapses são representadas pelo produto dos sinais de entrada (x_n) pelos pesos correspondentes (w_{nm}). O combinador linear realiza a combinação linear das sinapses juntamente com um elemento adicional chamado bias (b_n), que possui um peso específico. O uso do bias permite um controle mais preciso do valor que será fornecido à função de ativação (Júnior et al., 2005).

A função de ativação pode adotar diferentes formas e seu propósito principal é restringir a amplitude de saída do neurônio a um valor finito. Geralmente, os valores de saída são limitados a um intervalo específico, como -1 a 1 ou 0 a 1. A entrada da função de ativação corresponde à saída do combinador linear.

O modelo da Figura 3.2, pode ser expressado pelas equações 3.1 e 3.2.

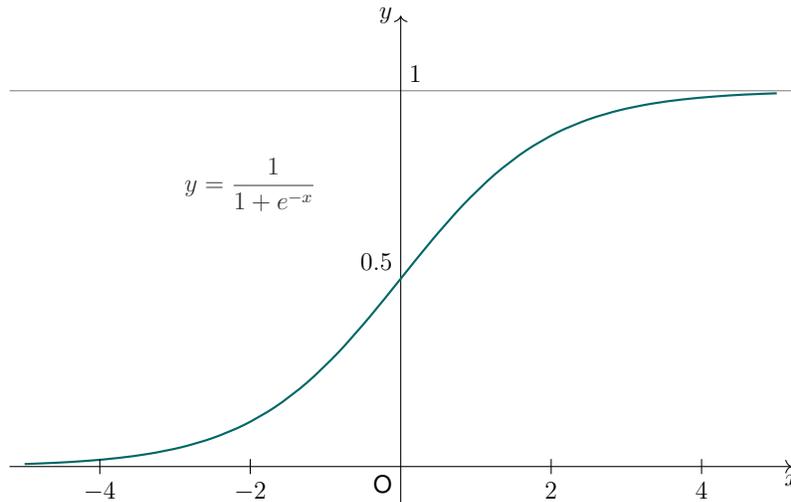
$$v_n = \sum_{m=0}^M w_{nm}x_m + b_n w_{bn} \quad (3.1)$$

$$y_n = \varphi(v_n) \quad (3.2)$$

O termo (v_n) representa o resultado do somatório da combinação linear das sinapses de entrada, juntamente com o bias (b_n) multiplicado pelo seu peso (w_{bn}). A função de ativação do neurônio é representada por φ , onde y é a saída do neurônio n -ésimo da rede, e M é o número de sinais de entrada.

A rede neural artificial pode utilizar diferentes tipos de funções de ativação. Entre elas, destacam-se a função sigmoide, a função tangente hiperbólica, a função limiar e a função limiar por partes. Nas aplicações da rede neural artificiais, as funções sigmoide e tangente hiperbólica são as mais comumente utilizadas.

Figura 3.3: Função Sigmoide.



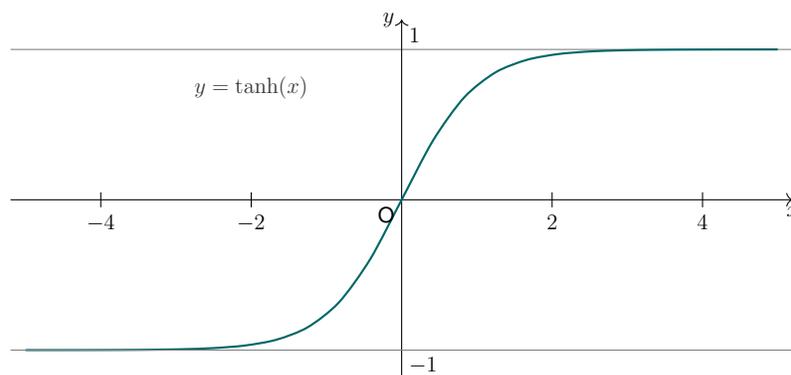
Fonte: Elaborado pelo autor (2024).

A função sigmoide é definida pela Equação 3.3 e seu comportamento é descrito pela Figura 3.3, com variação dos valores de (a) .

$$\varphi(x) = \frac{1}{1 + e^{-ax}} \quad (3.3)$$

A função tangente hiperbólica é definida pela Equação 3.4 e seu comportamento é descrito pela Figura 3.4, e os parâmetros (b) e (c) são constantes que controlam a amplitude e a inclinação da curva.

Figura 3.4: Função Tangente Hiperbólica.



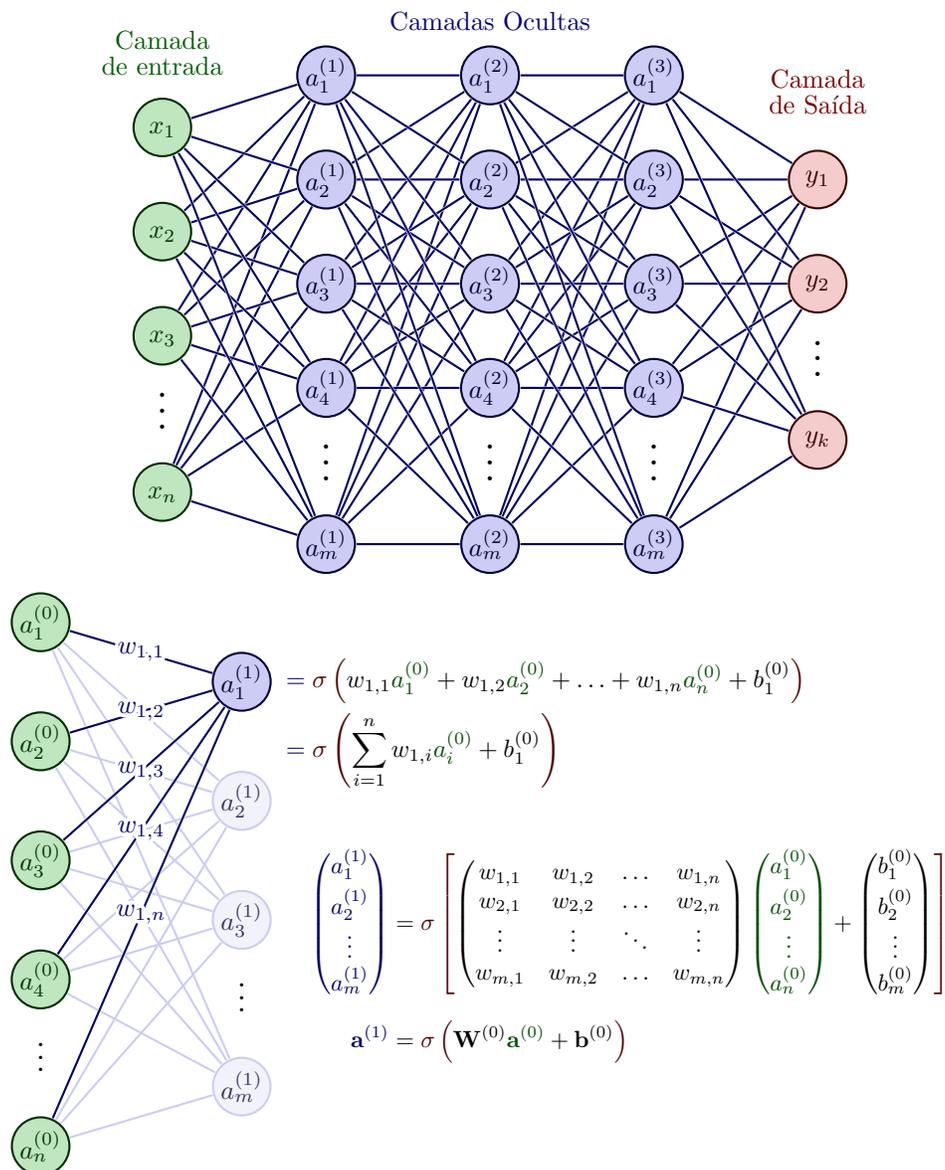
Fonte: Elaborado pelo autor (2024).

$$\varphi(x) = b \tanh(cx) \quad (3.4)$$

3.3 Tipos de Arquitetura de Rede Neural

Na literatura, existe uma grande variedade de arquiteturas de rede neural que são aplicadas em diversos tipos de casos. Entretanto, neste trabalho, será discutido apenas o uso das Redes Perceptron de Múltiplas Camadas. A Figura 3.5 demonstrará o tipo de arquitetura utilizada nessa pesquisa.

Figura 3.5: Rede perceptron de múltiplas camadas.



Fonte: Adaptado de Rusell and Norvig (2013).

Perceptron de Múltiplas Camadas

A rede neural *Multilayer Perceptron* (Perceptron Multicamadas) (MLP) é composta por uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Cada camada é formada por neurônios com várias entradas e uma única saída. Cada entrada é multiplicada por um peso associado, e cada saída passa por uma função de ativação. Os sinais de entrada dos neurônios são propagados pela rede (Haykin, 2001).

As redes Perceptron de múltiplas camadas têm sido amplamente empregadas na engenharia, incluindo o ramo da Engenharia de Materiais. Essas redes possuem a capacidade de aprender sobre um problema por meio de treinamento e generalizar para casos não apresentados a rede, o que as torna altamente valorizadas.

No entanto, uma desvantagem das redes Perceptron é que seu funcionamento é considerado uma “caixa preta”. Isso se deve à sua não-linearidade distribuída e à alta conectividade entre os neurônios, tornando difícil a análise teórica de seu funcionamento interno (Haykin, 2001).

Como mencionado anteriormente, cada neurônio possui uma função de ativação específica, sendo uma característica importante a suavidade das funções sigmoide e tangente hiperbólica. Essa suavidade facilita o cálculo de suas derivadas, o que desempenha um papel fundamental no desenvolvimento de algoritmos de treinamento para esse tipo de arquitetura.

Outra vantagem das funções sigmoide e tangente hiperbólica é que suas derivadas estão relacionadas às próprias funções primárias. Isso simplifica significativamente o processo de treinamento, reduzindo o número de cálculos necessários e, conseqüentemente, diminuindo o tempo de processamento durante o treinamento (Haykin, 2001).

A derivada obtida da função sigmoide é vista na Equação 3.5.

$$\frac{d\varphi(x)}{dx} = \frac{ae^{-ax}}{(1 + e^{-ax})^2} = a\varphi(x)(1 - \varphi(x)) \quad (3.5)$$

3.4 Treinamento de uma Rede Neural

A característica que é de importância crucial para uma rede neural é sua habilidade de aprendizado, através de regras pré-estabelecidas e do aprimoramento do seu desempenho por meio desse processo de aprendizagem.

O tipo de aprendizado é determinado pela maneira como ocorre a modificação dos parâmetros. O objetivo central do treinamento de uma rede neural é realizar uma modificação gradual dos seus pesos sinápticos, seguindo uma regra de aprendizado que determina a forma como esses pesos serão alterados.

Para possibilitar o aprendizado, é necessário dispor de um conjunto de dados de treinamento; durante o treinamento, cada vez que esse conjunto é apresentado à rede, ocorre uma época de aprendizado (Haykin, 2001).

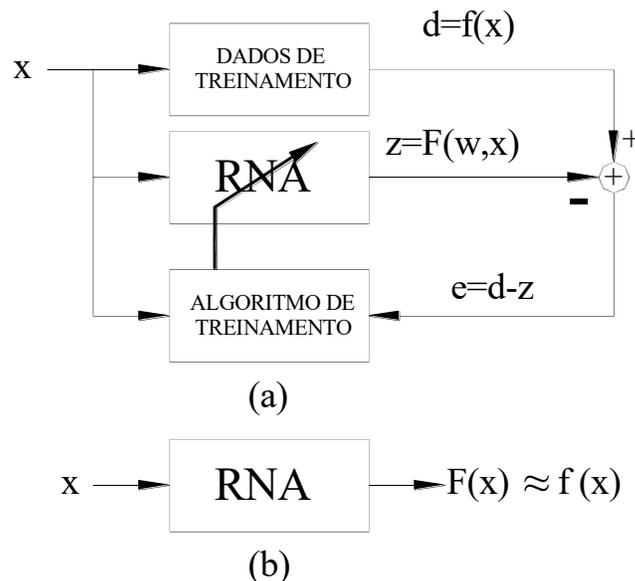
O algoritmo de treinamento é um conjunto pré-estabelecido de regras bem definidas para resolver um problema de aprendizagem. Existem vários tipos de algoritmos de treinamento, podendo ser classificados como supervisionados, semi-supervisionados e não-supervisionados. Neste trabalho, concentraremos nossa atenção apenas no treinamento supervisionado.

Treinamento Supervisionado

O treinamento supervisionado visa capacitar a RNA para responder de forma aproximada ao conjunto de dados apresentados a ela; além disso, almeja que a RNA tenha a capacidade de generalizar e gerar resultados aproximados para dados não utilizados no treinamento.

A Figura 3.6 ilustra um esquema do treinamento supervisionado; nela, a matriz de pesos sinápticos “ w ” é atualizada para que a RNA possa modelar-se aos dados apresentados no treinamento. Essas alterações na matriz “ w ” têm como propósito reduzir o erro existente entre os valores desejados (“ d ”) e os valores de saída (“ z ”).

Figura 3.6: Diagrama esquemático demonstrando o processo de aprendizado de uma rede neural, aonde (a) é o método de treinamento da RNA e (b) é o modelo obtido pelo treinamento da RNA.



Fonte: SILVA (2001).

Conforme mencionado anteriormente, há diversos tipos de algoritmos de treinamento, incluindo o Resilient Backpropagation (RPROP) (Riedmiller & Braun, 1993), o Quickprop (Fahlman et al., 1988) e o mais amplamente conhecido, o Backpropagation (Møller, 1993).

Cada um desses algoritmos possui suas particularidades e é solicitado de acordo com a aplicação específica, escolhendo aquele que melhor se ajusta às características do problema em questão.

As redes que empregam o algoritmo RPROP diferem das redes Backpropagation clássicas, onde, a cada iteração, com um tamanho de amostra específico, os pesos são atualizados na direção mais propensa (Riedmiller & Braun, 1993). O RPROP determina o tamanho do passo para cada interação de pesos individuais, com base na concordância ou discordância do sinal da derivada parcial em relação ao passo anterior. Sua principal vantagem é a capacidade de adaptar suas taxas de aprendizado à topologia do erro (Costa et al., 2021).

Algoritmo de Retroalimentação (Backpropagation)

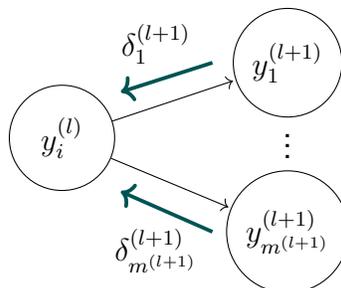
O algoritmo Backpropagation exige algumas características de arquitetura, das quais podemos citar: a função de ativação não linear deve possuir derivada em todos os pontos, a RNA deve possuir uma ou mais camadas de neurônios ocultos, e que a RNA deva possuir alto grau de conectividade. Aprovada essas características o objetivo do treinamento fica de reduzir o máximo possível o EMQ, também chamado de função custo, que é apresentado na Equação 3.6.

$$EMQ = \frac{1}{2Q} \sum_1^Q \sum_{p_1=1}^{P_1} (d_{p_1} - z_{p_1})^2 \quad (3.6)$$

Tendo em vista o objetivo de minimizar o EMQ, é necessário a modificação dos pesos sinápticos e isso é feito com a implementação do algoritmo de treinamento com propagação adiante e retro-propagação.

$\delta_i^{(L+1)}$ corresponde aos erros que são propagados de volta da camada $(l + 1)$ para camada (l) , como pode ser visualizado na Figura 3.7.

Figura 3.7: Retropropagação em redes profundas.

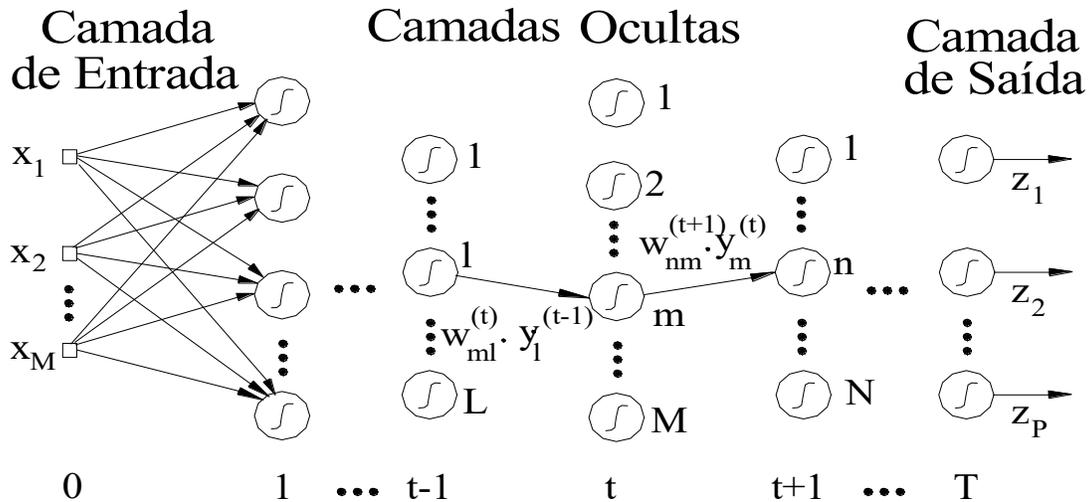


Fonte: Adaptado de Freire Jr and Aquino (2005).

Essas etapas computacionais podem ser interpretados como sinais. O sinal funcional percorre o interior da rede, e o sinal de erro é fornecido pelo algoritmo de treinamento, sendo assim, modifica a estrutura interna da rede (pesos sinápticos).

A modificação dos pesos sinápticos, através do sinal do erro, é realizada obedecendo as regras que são obtidas através da derivação da função custo em relação à variação dada aos pesos sinápticos.

Figura 3.8: Rede Perceptron de T camadas.



Fonte: Freire Jr and Aquino (2005).

Na Figura 3.8, os índices l , m e n , representam os neurônios de uma rede que se propaga da esquerda para a direita, tal que l é o neurônio que se encontra em uma camada a esquerda do neurônio m (camada anterior ao neurônio m) e o neurônio n se encontra uma camada a direita desse mesmo neurônio (camada posterior).

A partir das regras obtidas e considerando-se uma rede Perceptron de múltiplas camadas com “ T ” camadas (conforme mostrado na Figura 3.8) pode-se dividir o treinamento da rede em 5 etapas.

1. Início: A princípio devem ser escolhidos os valores dos pesos sinápticos aleatoriamente, de modo que a média dos seus valores seja zero e a variância se encontre próximo à saturação da função de ativação utilizada (a função de ativação utilizada pode ser sigmoide ou tangente hiperbólica).
2. Apresentação dos dados de treinamento: Apresenta-se uma época de exemplos de treinamento à rede. Para cada exemplo apresentado, realizam-se as sequencias descritas nos itens 3 e 4, na qual emite-se o sinal funcional e o sinal de erro.

3. Propagação adiante (sinal funcional): Propagação adiante (sinal funcional). Suponha que um exemplo de treinamento seja representado por $(x(q), d(q))$, sendo $x(q)$ o q -ésimo sinal (vetor) de entrada aplicado à camada de entrada da rede e $d(q)$ o vetor que se deseja que a rede apresente na sua saída após o treinamento (resposta desejada) para a entrada $x(q)$ (ver Figura 3.6). Em seguida são obtidos, os combinadores lineares $v_m^{(t)}(q)$ e os sinais funcionais $y_m^{(t)}(q)$, nos quais as notações m e t representam o m -ésimo neurônio na t -ésima camada da RNA.

As equações 3.7 e 3.8 representam, respectivamente, o combinador linear e o sinal funcional.

$$v_m^{(t)}(q) = \sum_{l=0}^L w_{ml}^{(t)}(q) y_l^{(t-1)}(q) \quad (3.7)$$

$$y_m^{(t)} = \varphi_m(v_m(q_m)) \quad (3.8)$$

Nestas equações, L representa o número total de sinais de entrada vindos da camada anterior $t - 1$ no m -ésimo neurônio da camada t , $y_l^{(t-1)}$ representa o sinal funcional obtido do l -ésimo sinal de saída da camada anterior a t , $y_m^{(t)}$ é o sinal de saída do m -ésimo neurônio da camada t e $\phi(\cdot)$ é a função de ativação da rede que pode ser a função sigmoide (Equação 3.3) ou a tangente hiperbólica (Equação 3.7).

Se o neurônio m está na primeira camada oculta ($t = 1$), use a Equação (3.9) em (3.7).

$$y_m^{(0)} = x_m(q) \quad (3.9)$$

Quando o neurônio m está na camada de saída ($t = T$), use a Equação (3.10), para a obtenção do sinal de saída da rede.

$$z_m(q) = y_m^{(T)} \quad (3.10)$$

Com o sinal de saída da rede $z_m(q)$ e a resposta desejada $d_m(q)$ para o m -ésimo neurônio de saída calcule o sinal do erro em (q) , conforme a Equação 3.11.

$$e_m = d_m(q) - z_m(q) \quad (3.11)$$

4. Retropropagação (sinal do erro): Calcule os gradientes locais da rede δ (Equação 3.12).

$$\delta_m^{(t)}(q) = \begin{cases} e_m^{(T)}(q) \phi'_m(v_m^{(T)}(q)) & \text{Neurônio } m \text{ na camada de saída } (T) \\ \phi'_m(v_m^{(t)}(q)) \sum_n \delta_n^{(t+1)}(q) w_{nm}^{(t+1)}(q) & \text{Neurônio } m \text{ na camada oculta } (t) \end{cases} \quad (3.12)$$

Na equação acima, $\phi'_m(\cdot)$ é a derivada da função de ativação do m -ésimo neurônio da camada t , para o caso da função sigmoide a derivada pode ser vista na Equação 3.5. Com os valores dos gradientes locais, modifique os pesos sinápticos usando a Equação 3.13.

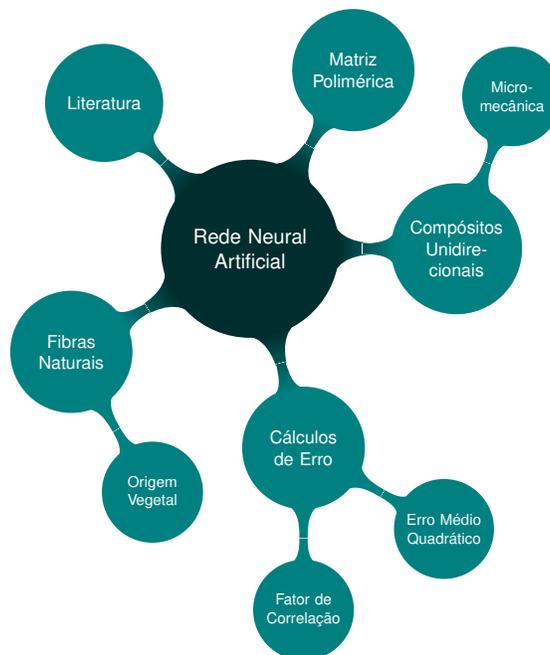
$$w_{ml}^{(t)}(q+1) = w_{ml}^{(t)}(q) + \alpha [w_{ml}^{(t)}(q) - w_{ml}^{(t)}(q-1)] + \eta \delta_m^{(t)}(q) y_l^{(t-1)}(q) \quad (3.13)$$

Na Equação 3.13, η e α são a taxa de aprendizagem e a constante do momento, respectivamente. Tanto a taxa de aprendizagem quanto a constante do momento são valores escolhidos pelo programador e, de preferência, devem ficar entre 0 e 1. Esses valores podem, ou não, variar durante o treinamento da rede, objetivando diminuir o número de iterações e melhorar o resultado obtido pela mesma.

5. Iteração: Apresentação dos dados de treinamento deve ser feita várias vezes, o número de iterações, ou seja, o número de vezes que o conjunto de treinamento deve ser apresentado, vai depender do critério de parada escolhido pelo usuário.

Foram desenvolvidas três arquiteturas, sendo as três, baseadas em rede perceptron de múltiplas camadas, treinadas pelo algoritmo Backpropagation. Na Figura 4.1, pode-se visualizar o mapa mental da arquitetura referente à rede neural.

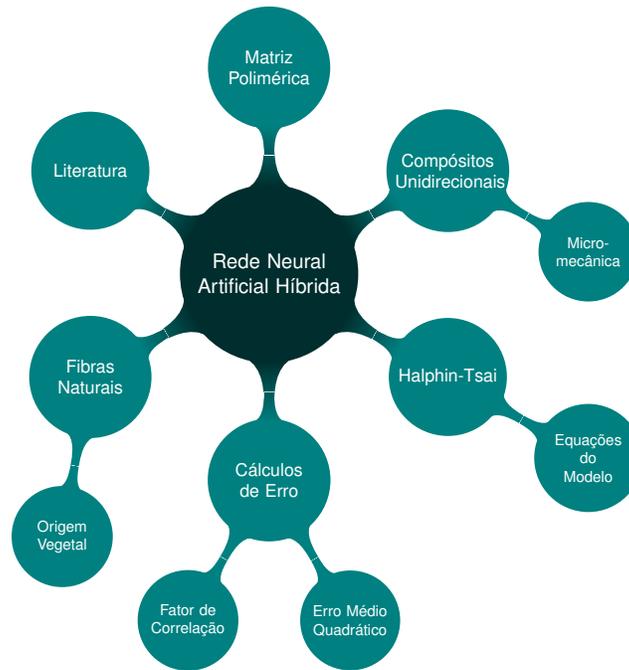
Figura 4.1: Mapa mental da arquitetura da RNA.



Fonte: Elaborado pelo autor (2024).

Das três arquiteturas mencionadas, duas são compostas exclusivamente por redes neurais. Uma dessas arquiteturas possui duas entradas, enquanto a outra possui três entradas. A terceira arquitetura é uma abordagem híbrida, conforme ilustrado na Figura 4.2, que utiliza uma RNA de três entradas apenas para aprimorar os resultados obtidos pelas equações do modelo utilizado.

Figura 4.2: Mapa mental da arquitetura da RNA Híbrida.



Fonte: Elaborado pelo autor (2024).

Especificamente, o modelo de Halpin-Tsai foi empregado no algoritmo híbrido, e também foi utilizado o modelo de Halpin-Tsai “puro” para servir como elemento de comparação para os modelos propostos anteriormente.

O treinamento dos três algoritmos empregou a validação cruzada K-Fold para avaliação de desempenho durante o treinamento. Os conjuntos de dados foram divididos em um conjunto de treinamento (70% do conjunto de dados) e um conjunto de teste (30% do conjunto de dados) com o objetivo de desenvolver uma rede com boa capacidade de generalização. Todas as arquiteturas de RNA utilizaram duas camadas ocultas com o número de neurônios variando entre 10 e 50 para verificar qual configuração interna apresentaria os melhores resultados nessa faixa. Todos os neurônios foram dotados de bias e usaram a função de ativação sigmoide, exceto o neurônio de saída, que usou a função de ativação linear. O algoritmo de treinamento empregado foi o de retropropagação, baseado na regra do momento (Haykin, 2001).

Os modelos de duas entradas, três entradas e híbrido foram treinados até no máximo 5000 épocas, utilizando uma taxa de aprendizado de 0.005 e uma constante de momento de 0.7 em todas as etapas. Importante destacar que tanto os neurônios de entrada quanto os neurônios de saída tiveram seus dados normalizados para melhorar o aprendizado da RNA.

Foi analisado o coeficiente de correlação (r) e o EMQ. O estudo desses pontos, tanto para a RNA quanto para o critério de Halpin-Tsai, permitiu a comparação entre ambos e contribuiu para a validação da RNA.

Abaixo está a Equação 4.1 do EMQ, onde E_{2real} é o valor “real” do módulo de elasticidade transversal, vindo dos valores experimentais, e E_{2rna} é o valor calculado pela RNA e pelas equações de Halpin-Tsai. O termo (n) é a quantidade de dados usados.

$$EMQ = \frac{1}{2n} \sum (E_{real} - E_{rna})^2 \quad (4.1)$$

4.1 Pré-processamento dos Dados

O pré-processamento de dados é uma etapa crucial em muitas aplicações de ciência de dados e aprendizado de máquina, incluindo modelagem de RNA. Envolve uma série de técnicas destinadas a preparar os dados brutos para modelagem, garantindo que estejam em um formato adequado para serem utilizados pelos algoritmos de aprendizado (Paixão, Penido, Cury, & Mendes, 2022).

Dados Obtidos na Literatura

Para determinar o módulo de elasticidade transversal, foram necessários os seguintes parâmetros mecânicos dos compósitos unidirecionais: módulo de elasticidade da fibra (E_f), módulo de elasticidade da matriz (E_m) e fração volumétrica da fibra (V_f). A busca por esses dados envolveu a consulta a artigos científicos, livros e relatórios técnicos (Agropecuária & GrandelPB, 2009; Castro, 2013; de Castro & Grattapaglia, 2014; Ishizaki, Visconte, Furtado, Leite, & Leblanc, 2006; Kumaresan, Sathish, Karthi, et al., 2015; Lemos & Martins, 2014; Martin, Martins, Mattoso, & Silva, 2009; Martins, Iozzi, Martins, Mattoso, & Ferreira, 2004; Monteiro, Rodriguez, Lopes, & Sores, 2013; Pinto, A Júnior, Carvalho, et al., 2005; Prasad, Gowda, & Velmurugan, 2017; S. O. Silva, 2021; T. L. S. Silva, de Oliveira Filho, & do Nascimento Silva., 2024).

No processo de treinamento da RNA, inicialmente foram coletados dados de 74 compósitos unidirecionais para formar o conjunto de dados inicial. Entretanto, para aumentar a representatividade do conjunto de dados, realizou-se uma interpolação, expandindo o número de compósitos para 300. Com este novo conjunto expandido, a distribuição entre dados de treinamento e teste agora possui 210 compósitos destinados ao treinamento e 90 para teste.

Esses compósitos abrangiam uma variedade de materiais para a fibra e para a matriz, além de diferentes percentuais de fibra, variando de 20% a 70%. É importante ressaltar que, para a

determinação do módulo de elasticidade transversal, foram utilizadas exclusivamente lâminas unidirecionais em todo o conjunto de dados.

As fibras utilizadas na fabricação das lâminas unidirecionais foram feitas de vários tipos de materiais dentre elas as fibra de sisal (*agave sisalana*), juta, coco. As matrizes avaliadas foram: poliéster, epóxido, polipropileno, poliuretano.

As Tabelas 4.1, 4.2 e 4.3 apresentam, respectivamente, os valores dos módulos de elasticidade transversal da fibra, da matriz e dos compósitos unidirecionais utilizados no decorrer do estudo.

Tabela 4.1: Valores coletados da literatura do módulo de elasticidade transversal para fibra.

Fibras	Módulo da Fibra (GPa)
Sisal	3.62 – 9.17
Juta	10.19 – 11.04
Coco	1.54 – 2.50

Fonte: Elaborado pelo autor (2024).

Tabela 4.2: Valores coletados da literatura do módulo de elasticidade transversal para matriz.

Matriz	Módulo da Matriz (GPa)
Poliéster	2.06 – 4.41
Epóxido	2.3 – 4.6
Polipropileno	1.14 – 1.55
Poliuretano	1.1 – 3.6

Fonte: Elaborado pelo autor (2024).

Tabela 4.3: Valores do módulo de elasticidade transversal de compósitos unidirecionais.

Compósito	Módulo Transversal (GPa)
Sisal/Epóxido	6.33 – 13.44
Sisal/Poliéster	6.11 – 13.21
Sisal/Poliuretano	1.78 – 6.14
Juta/Epóxido	6.53 – 14.90
Juta/Poliéster	6.30 – 14.71
Juta/Polipropileno	2.12 – 7.30
Coco/Epóxido	4.53 – 5.56
Coco/Poliéster	4.65 – 5.41
Coco/Poliuretano	1.31 – 2.56

Fonte: Elaborado pelo autor (2024).

Interpolação dos Dados

Um aspecto fundamental do processo de preparação dos dados para análise foi a aplicação de interpolação linear. Inicialmente, o conjunto de dados consistia em 74 compósitos unidirecionais. Reconhecendo a necessidade de aumentar a representatividade do conjunto de dados,

optou-se por realizar uma interpolação linear. Esta técnica permitiu expandir o conjunto de dados para um total de 300 compósitos (S. Silva et al., 2020).

Essa expansão foi essencial para garantir uma distribuição mais abrangente e representativa dos dados, o que é essencial para o treinamento de modelos de rede neural (Dantas et al., 2020).

Normalização dos Dados

A normalização é uma técnica fundamental em muitas áreas da ciência de dados e da aprendizagem de máquina, sendo essencial para preparar os dados antes de aplicar algoritmos de treinamento ou análise estatística (Lima, 2021).

Entre as diversas abordagens de normalização, a normalização Min-Max se destaca como uma das mais simples e amplamente utilizadas, permitindo uma comparação mais consistente entre diferentes conjuntos de dados ou variáveis. É fundamental destacar que, como a fração volumétrica varia de 0 a 1, não houve necessidade de normalizar esse parâmetro de entrada (Lopes, 2024).

O valor original E_2 é ajustado para E_{2nor} de forma que esteja na escala entre E_{2min} e E_{2max} .

$$E_{2nor} = \frac{E_2 - E_{2min}}{E_{2max} - E_{2min}} \quad (4.2)$$

onde:

E_{2nor} é o valor normalizado,

E_2 é o valor original do módulo de elasticidade transversal,

E_{2min} é o valor mínimo no conjunto de dados,

E_{2max} é o valor máximo no conjunto de dados.

O valor original E_f é ajustado para E_{fnor} de forma que esteja na escala entre E_{fmin} e E_{fmax} .

$$E_{fnor} = \frac{E_f - E_{fmin}}{E_{fmax} - E_{fmin}} \quad (4.3)$$

onde:

$E_{f_{nor}}$ é o valor normalizado,
 E_f é o valor original do módulo de elasticidade da fibra,
 $E_{f_{min}}$ é o valor mínimo no conjunto de dados,
 $E_{f_{max}}$ é o valor máximo no conjunto de dados.

O valor original E_m é ajustado para $E_{m_{nor}}$ de forma que esteja na escala entre $E_{m_{min}}$ e $E_{m_{max}}$.

$$E_{m_{nor}} = \frac{E_m - E_{m_{min}}}{E_{m_{max}} - E_{m_{min}}} \quad (4.4)$$

onde:

$E_{m_{nor}}$ é o valor normalizado,
 E_m é o valor original do módulo de elasticidade da matriz,
 $E_{m_{min}}$ é o valor mínimo no conjunto de dados,
 $E_{m_{max}}$ é o valor máximo no conjunto de dados.

Métodos de reamostragem

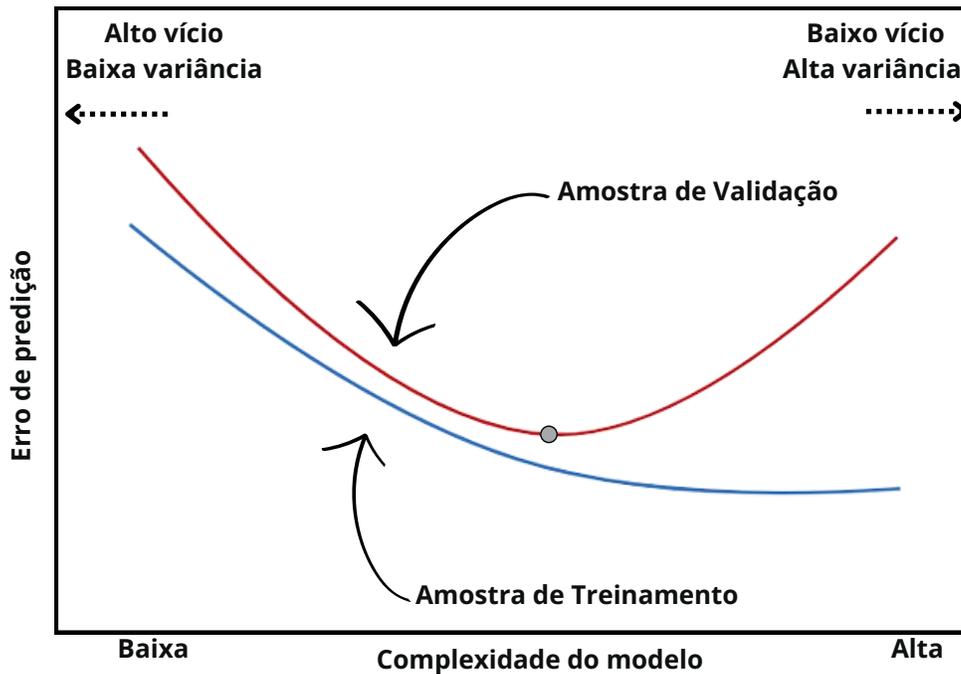
Métodos de reamostragem são ferramentas indispensáveis na estatística moderna. As técnicas envolvem particionar os dados de treino e reajustar os modelos em competição para cada subamostra, a fim de obter informações adicionais sobre o ajuste do modelo, algo que não seria possível com os dados completos (Ferreira, 2018).

Por exemplo, por meio dos métodos de reamostragem, podemos estimar o erro de teste associado a um determinado modelo e realizar a seleção do modelo com o nível apropriado de flexibilidade (Ferreira, 2018).

Isso se traduz no treinamento do algoritmo com uma amostra de treinamento representada pela curva azul na Figura 4.3 e na avaliação da qualidade do ajuste com uma amostra de validação, indicada pela curva vermelha. É importante observar que o uso de algoritmos muito simples resultará em um alto erro de predição na amostra de treinamento, representada pela curva azul, enquanto a complexidade crescente do modelo tende a reduzir esse erro de treinamento.

Entretanto, essa aparente melhoria é acompanhada por uma diminuição na capacidade de generalização, ou seja, o desempenho do modelo ao lidar com novos exemplos, como a amostra de validação, pode ser insatisfatório.

Figura 4.3: Erro de predição por complexidade do modelo.



Fonte: Adaptado de Ferreira (2018).

Tendo em vista essa questão, o desafio reside em encontrar um equilíbrio entre um modelo simples, que pode estar subajustado, e um modelo complexo, que pode estar superajustado, de modo que o erro seja minimizado quando novos dados forem introduzidos.

Validação-Cruzada: K-Fold

Separar os dados em somente duas partes disjuntas pode trazer resultados divergentes, dependendo da informação contida em cada conjunto, especialmente quando os dados são escassos. A abordagem de validação cruzada por k-fold, minimiza esses problemas (Leal, 2019).

O método consiste em dividir os dados em K partes iguais, ajustando o modelo utilizando $K-1$ partes, e a parcela restante fica destinada à validação. Esse processo é repetido K vezes, em cada momento uma partição diferente será a validação; em seguida, os resultados são combinados obtendo a média dos erros obtidos (Cunha, 2019).

Definição:

- Sejam K partes denotadas por C_1, C_2, \dots, C_K , em que C_k representa o índice da k -

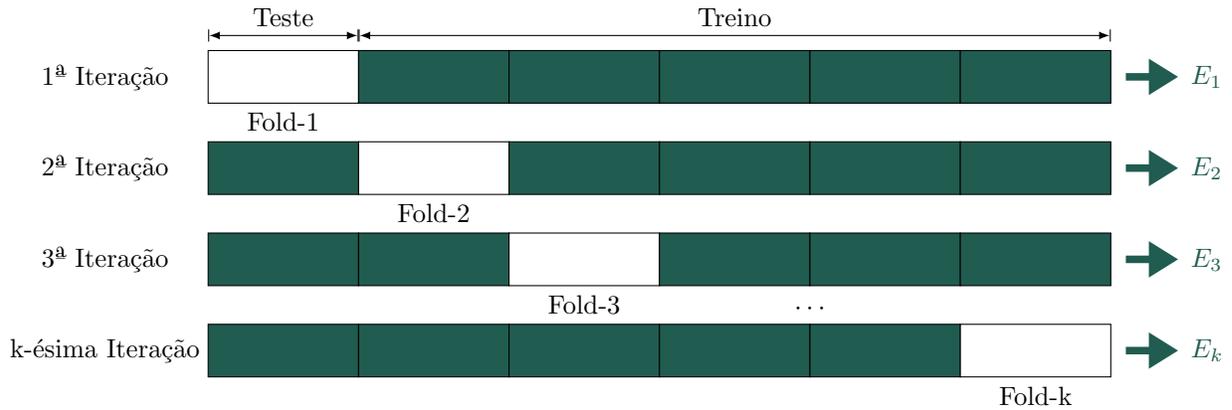
ésima parte.

- Considere ainda que temos n_k observações na partição k (se n é múltiplo de K , então $n_k = \frac{n}{K}$).
- Calcule:

$$CV_{(K)} = \sum_{k=1}^K \frac{n_k}{n} EMQ_k, \quad (4.5)$$

em que $EMQ_k = \frac{\sum_{i \in C_k} (y_i - \hat{y}_i)^2}{n_k}$, e \hat{y}_i é o valor ajustado da observação i , obtido dos dados com a k -ésima parte removida. A abordagem de validação cruzada por k-fold, representada na Figura 4.4.

Figura 4.4: Validação cruzada por k-fold.



Fonte: Adaptado de Cunha (2019).

$$\bar{E} = \frac{1}{k} \sum_{i=1}^k E_i \quad (4.6)$$

onde:

\bar{E} representa a média da métrica ao longo de todos os folds.

k é o número total de folds na k-fold validação-cruzada.

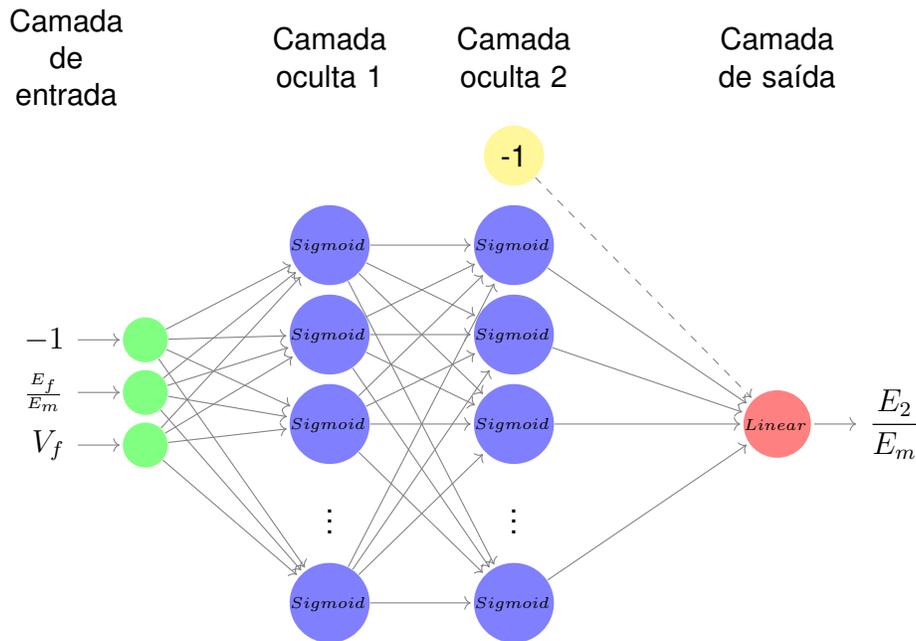
E_i é a métrica de desempenho no i -ésimo fold.

Essa Equação 4.6 calcula a média da métrica de desempenho (E) ao longo de todos os folds em uma k-fold validação-cruzada, onde E_i é a métrica de desempenho no i -ésimo fold. A soma é feita sobre todos os folds, de 1 a k , e o resultado é então dividido pelo número total de folds k para obter a média.

4.2 Modelo RNA de Duas Entradas

A arquitetura da RNA representada na Figura 4.5 é constituída por dois neurônios de entrada e um neurônio de saída.

Figura 4.5: Arquitetura da rede neural com duas entradas.



Fonte: Adaptado de Oliveira (2018).

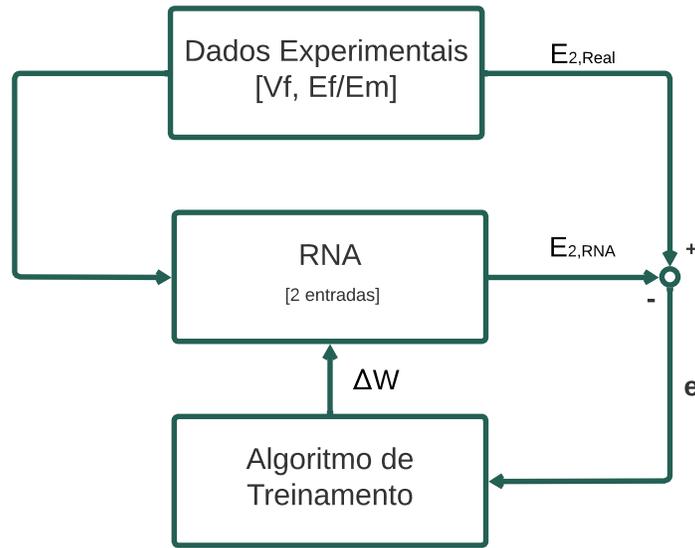
Assim sendo, um neurônio de entrada que representa a razão do módulo de elasticidade da fibra pelo módulo de elasticidade da matriz, um neurônio de entrada que representa o volume de fibra e um neurônio de saída representado pela razão do módulo de elasticidade transversal pelo módulo de elasticidade da matriz.

A Equação 4.7 tem como objetivo modelar com a RNA, aonde, $\frac{E_f}{E_m}$ é a razão do módulo de elasticidade da fibra pelo módulo de elasticidade da matriz, $\frac{E_2}{E_m}$ representa a razão do módulo de elasticidade transversal pelo módulo de elasticidade da matriz e V_f é o volume de fibra.

$$\frac{E_2}{E_m} = f \left(\frac{E_f}{E_m}, V_f \right) \quad (4.7)$$

Nesse tipo em específico de arquitetura, sua principal função é a simplificação dos dados utilizados, obtendo uma diminuição do número de pesos sinápticos da rede. Na Figura 4.6, pode ser visualizada a arquitetura de treinamento da RNA com duas entradas.

Figura 4.6: Arquitetura de treinamento para RNA duas entradas.

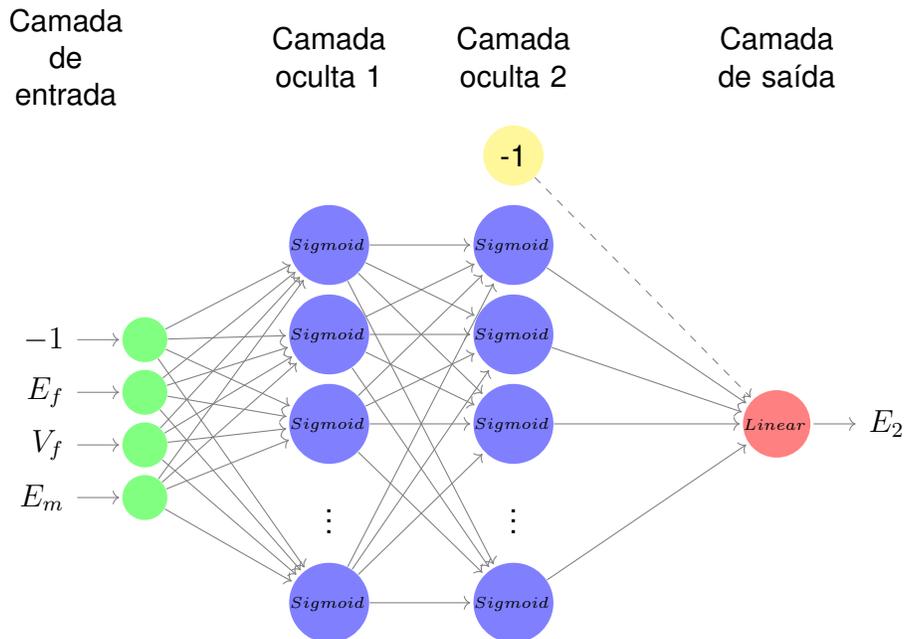


Fonte: Adaptado de E. C. B. Câmara (2012).

4.3 Modelo RNA de Três Entradas

A arquitetura da RNA representada na Figura 4.7 é constituída por três neurônios de entrada e um neurônio de saída.

Figura 4.7: Arquitetura da rede neural com três entradas.



Fonte: Adaptado de Oliveira (2018).

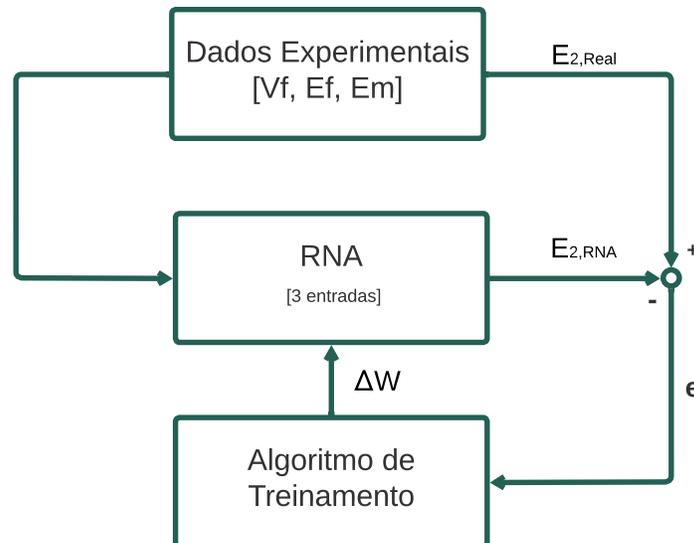
Assim sendo, um neurônio de entrada que representa módulo de elasticidade da fibra, um neurônio de entrada que representa o volume de fibra, um neurônio de entrada que representa o módulo de elasticidade da matriz e um neurônio de saída representado pelo módulo de elasticidade transversal.

A Equação 4.8 tem a função que deseja modelar a arquitetura de três entradas. Sendo assim, E_2 o módulo de elasticidade transversal, E_f o módulo de elasticidade da fibra, E_m o módulo de elasticidade da matriz e V_f o volume de fibra.

$$E_2 = f(E_f, E_m, V_f) \quad (4.8)$$

Na Figura 4.8, mostra a arquitetura de treinamento desta RNA, mudando os tipos de dados que vão servir de comparação para o funcionamento do algoritmo backpropagation, representado por ΔW a atualização dos pesos sinápticos, vindo do algoritmo de treinamento.

Figura 4.8: Arquitetura de treinamento para RNA três entradas.



Fonte: Adaptado de E. C. B. Câmara (2012).

4.4 Modelo híbrido RNA de três Entradas

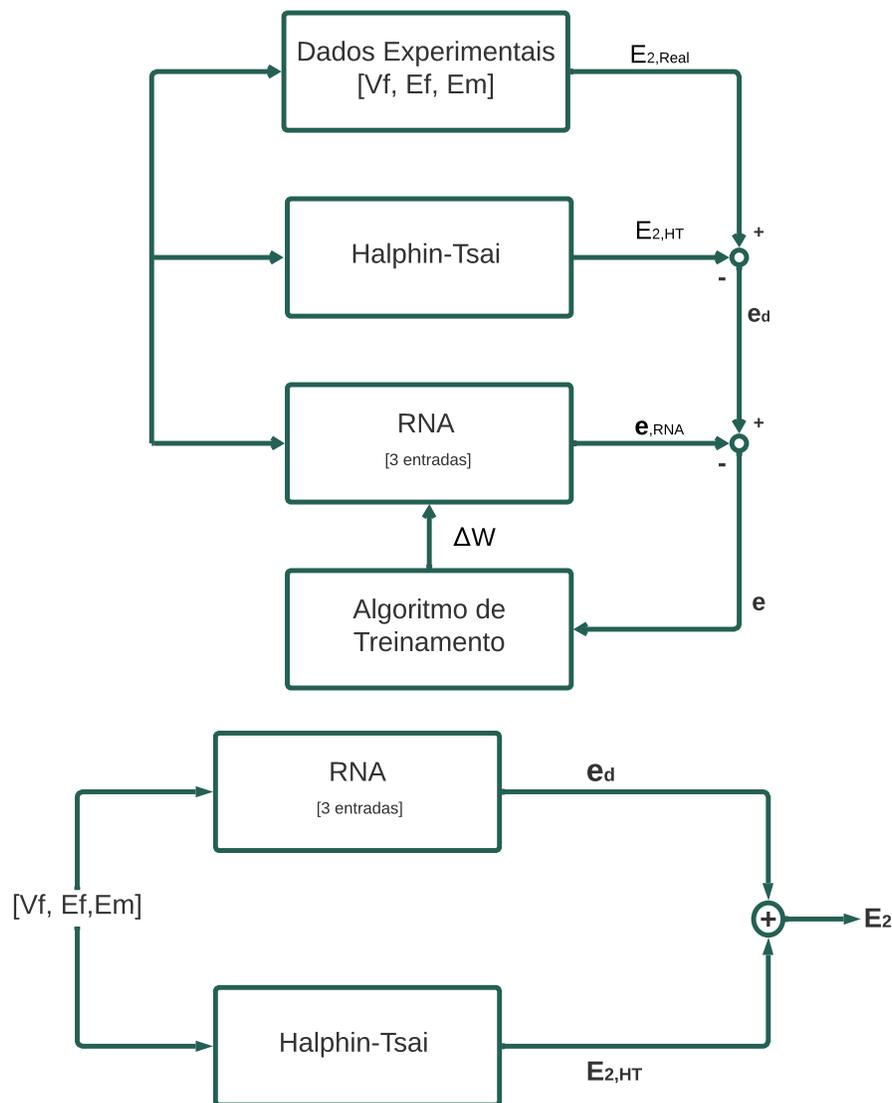
O modelo híbrido, possui uma estrutura formada por uma RNA e um modelo de cálculo semi-empírico, sendo utilizado o modelo de Halpin-Tsai. Sua aplicação terá como função aproximar o modelo analítico do resultado de (E_{2real}) dos valores obtidos experimentalmente, retirados da literatura.

Para esse exemplo, a saída da RNA é o erro (e_d), que é dado pela diferença entre os valores dos módulos de elasticidade transversais (E_{2real}) obtidos experimentalmente e os valores dos módulos de elasticidade transversais obtidos a partir das equações de Halpin-Tsai ($E_{2estimado}$).

$$e_d = E_{2real} - E_{2estimado} \quad (4.9)$$

Na Figura 4.9, o valor de ΔW representa a atualização dos pesos sinápticos, proveniente do algoritmo de treinamento. Existe uma aproximação analítica para obter o valor de E_2 , porém, visando aprimorar os resultados, é utilizada uma RNA.

Figura 4.9: Arquitetura de treinamento e fluxograma da RNA de três entradas com Halphin-Tsai.



Fonte: Adaptado de E. C. B. Câmara (2012).

Resultados

Nesta seção, serão mostrados os principais resultados dos treinamentos da Rede Neural Artificial (RNA) para a análise da propriedade mecânica E_2 , juntamente com seus modelos propostos de duas e três entradas, além do modelo híbrido. Será realizado, também, uma comparação para validação da RNA relacionada com o módulo de elasticidade transversal (E_2), e o modelo teórico (Halpin-Tsai). Para fornecer um ponto inicial para a análise, os resultados obtidos pelo modelo de Halpin-Tsai são comparados aos dados experimentais. O EMQ obtido entre os dados experimentais e o modelo de Halpin-Tsai foi de 0.006574, enquanto o coeficiente de correlação foi de 0.9131.

5.1 RNA de Duas Entradas

Utilizando validação cruzada, avaliou-se inicialmente o EMQ da RNA em relação às épocas de treinamento da rede. No caso de uma arquitetura com duas entradas, constatou-se que, apesar dos menores valores de EMQ obtidos para o conjunto de dados de teste, os valores para o conjunto de dados de treinamento permaneceram elevados, conforme ilustrado na Figura 5.1, atingindo aproximadamente 0.006986, superior ao modelo de Halpin-Tsai, que alcançou 0.006574. Além disso, observa-se que no início do treinamento não há uma redução significativa do EMQ do conjunto de treinamento, o que provavelmente resultará em uma RNA incapaz de generalizar e modelar os dados de forma satisfatória.

Na Figura 5.2, foi realizada uma análise comparativa focada nos valores de E_2 gerados pela RNA. Os dados de treinamento e de teste foram analisados em um gráfico de valores, onde é perceptível que, quanto mais próximos esses valores estão da linha vermelha, maior é a linearidade entre os valores da RNA e os experimentais. Os valores se mostraram bem distribuídos para os valores baixos, enquanto que, para valores maiores, a RNA encontrou valores inferiores aos experimentais. Nesse modelo, observa-se que os dados de teste, tiveram valores distantes da linha comparativa.

Figura 5.1: Análise do EMQ pelo número de épocas de treinamento da RNA de Duas Entradas.

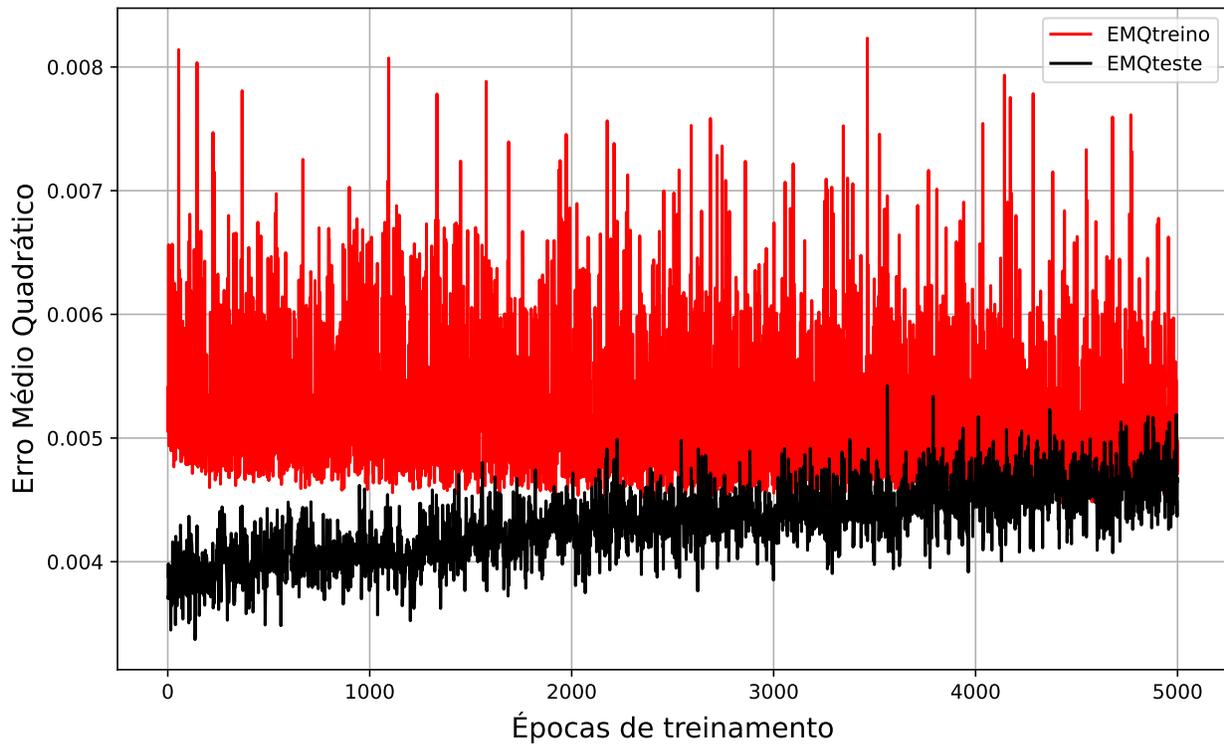
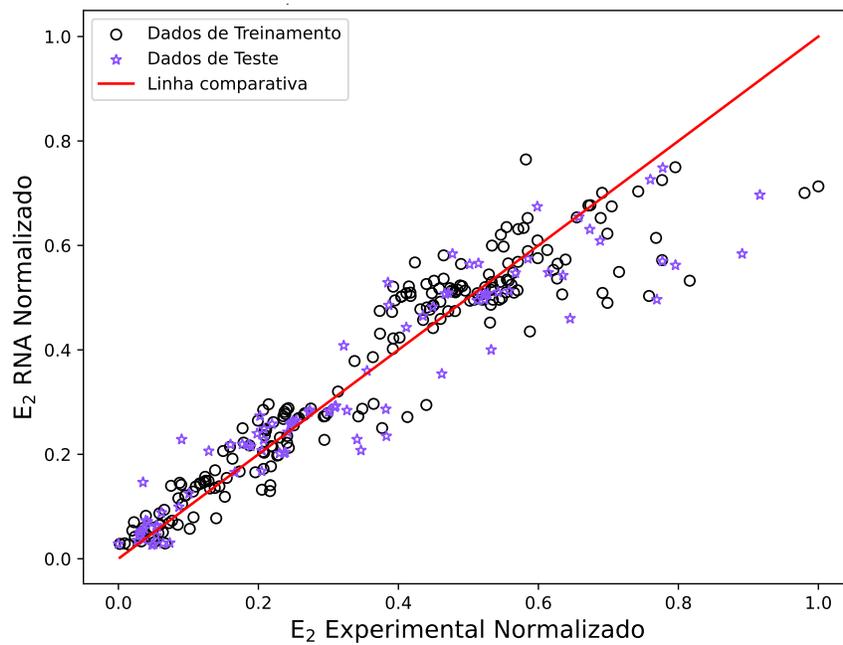


Figura 5.2: Gráfico comparativo da RNA de Duas Entradas.

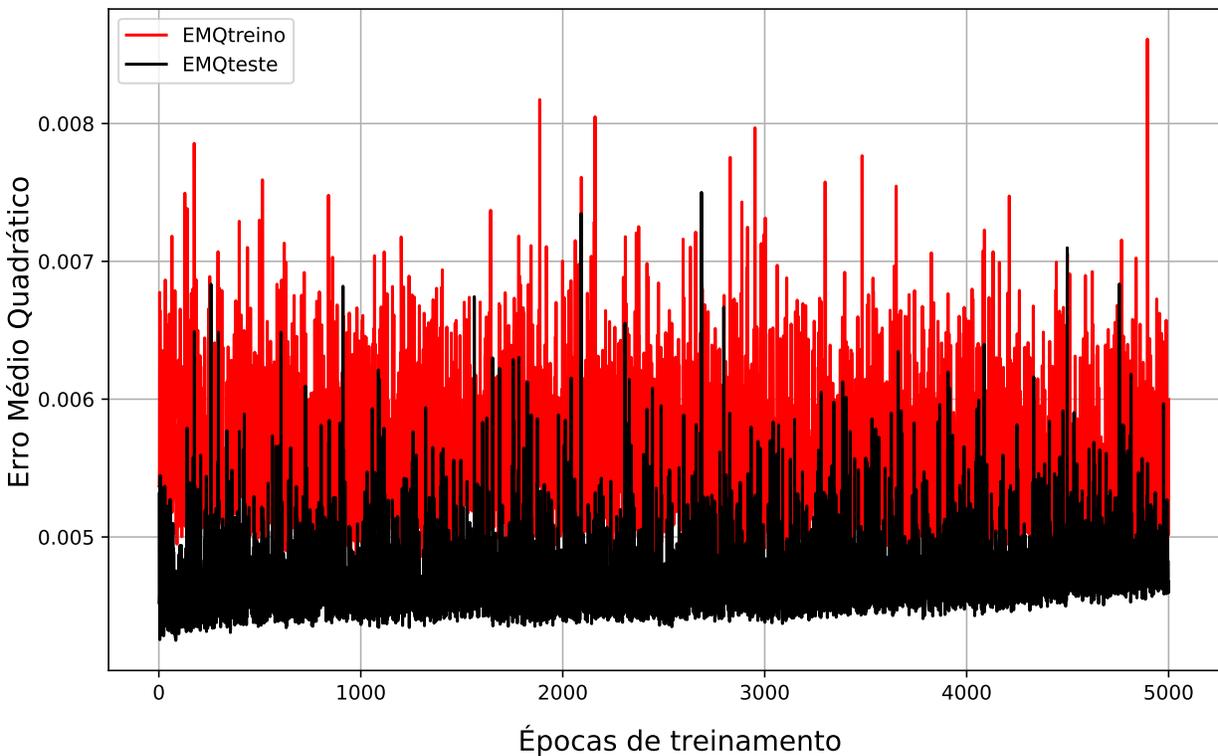


5.2 RNA de Três Entradas

Conforme feito na arquitetura anterior, utilizou-se novamente a validação cruzada como critério de parada desta RNA. Ou seja, um conjunto de teste foi usado para a escolha dos pesos sinápticos da RNA. Analisando a curva de erro médio quadrático em função do número de épocas de treinamento para o melhor resultado obtido, que foi com 48 neurônios na camada oculta, conforme mostrado na Figura 5.3, percebe-se que há um acompanhamento das duas curvas na mesma ordem de grandeza. Esse comportamento não ocorreu na RNA de duas entradas, onde se verificou uma diferença significativa entre os dados. Este fato pode servir como indício de que a RNA de três entradas está conseguindo generalizar melhor o comportamento micromecânico do que a RNA de duas entradas.

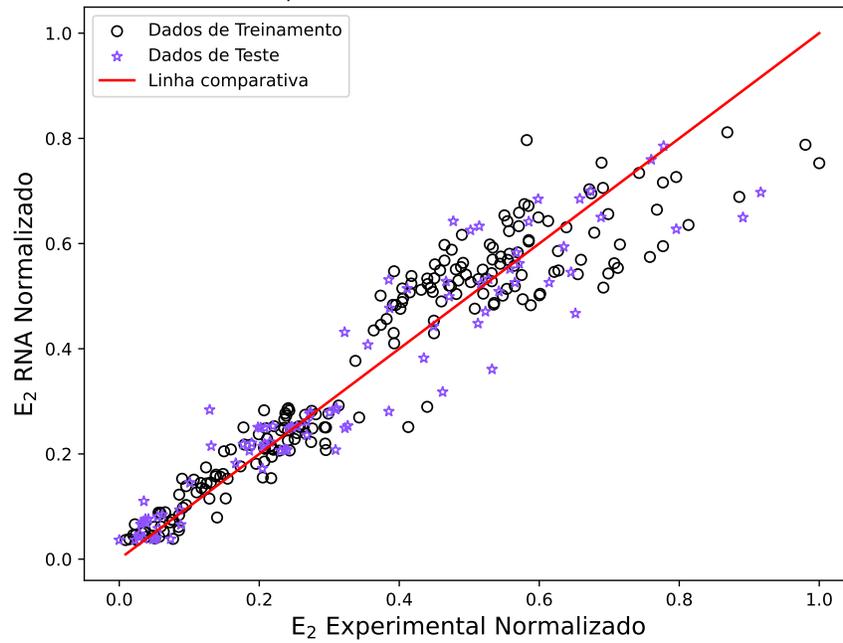
Na Figura 5.4, foi realizada uma análise comparativa similar àquela feita com a RNA de duas entradas, focando nos valores de E_2 gerados pela RNA. Os valores mostraram uma boa distribuição para os valores baixos, enquanto, para valores mais altos, houve uma melhora em relação à RNA de duas entradas, especialmente nos valores inferiores dos dados experimentais. Nesse modelo, observa-se que os dados de teste apresentaram uma melhora em comparação com a RNA de duas entradas, considerando a linha comparativa.

Figura 5.3: Análise do EMQ pelo número de épocas de treinamento da RNA de Três Entradas.



Fonte: Elaborado pelo autor (2024).

Figura 5.4: Gráfico comparativo da RNA de Três Entradas.



Fonte: Elaborado pelo autor (2024).

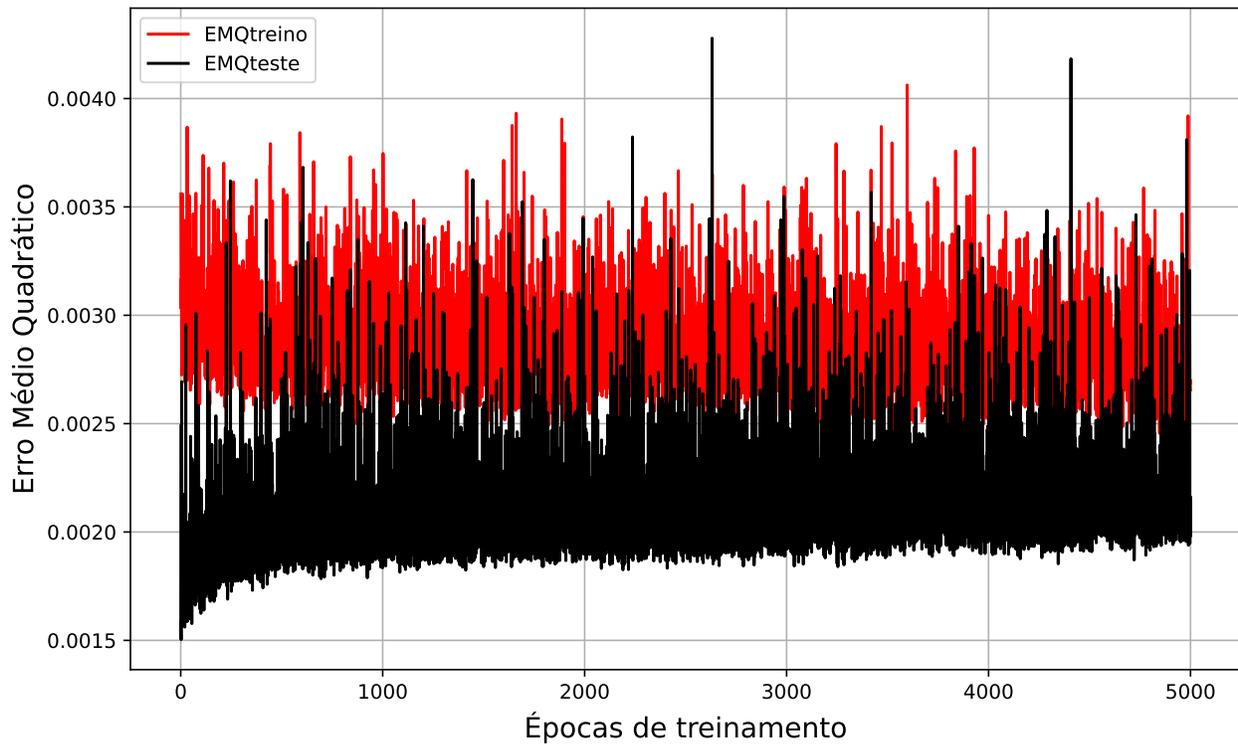
5.3 Modelo Híbrido RNA de Três Entradas.

O modelamento híbrido utilizado aqui combina um modelo teórico de Halpin-Tsai com uma RNA para ajustar adequadamente os dados experimentais. De qualquer modo, assim como nas duas arquiteturas anteriores, a validação cruzada foi utilizada como critério de parada, buscando obter a resposta mais apropriada aos dados experimentais.

Pensando dessa forma, a arquitetura que apresentou os melhores resultados possui 24 neurônios na camada oculta. Conforme pode ser verificado na Figura 5.5, que mostra os valores de erro médio quadrático para o conjunto de treinamento e teste, este resultado foi observado na RNA de três entradas, que também apresentou resultados satisfatórios e não foi observado na RNA de duas entradas, cujos resultados se mostraram pouco confiáveis. Com este resultado, percebe-se que o modelo misto também pode ter a capacidade de generalizar o comportamento micromecânico das lâminas unidirecionais.

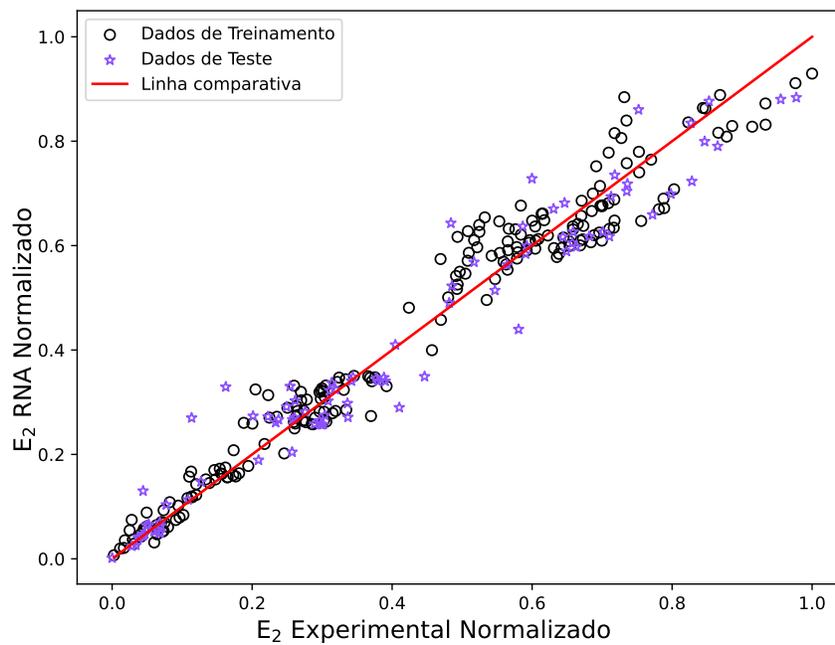
O modelo Híbrido se baseia nos valores das equações semi-empíricas de Halpin-Tsai para, juntamente com uma RNA, realizar um ajuste nessas equações de modo a aproximar seus resultados aos valores experimentais. Nesse modelo, observa-se uma maior proximidade dos valores da RNA mista com os valores reais, principalmente nos dados de treinamento, quando comparado com os outros modelos. Na Figura 5.6, observa-se também que os valores ficaram mais próximos da linha comparativa.

Figura 5.5: Análise do EMQ pelo número de épocas de treinamento da RNA modelo Híbrido.



Fonte: Elaborado pelo autor (2024).

Figura 5.6: Gráfico comparativo da RNA modelo Híbrido.



Fonte: Elaborado pelo autor (2024).

5.4 Análise Comparativa

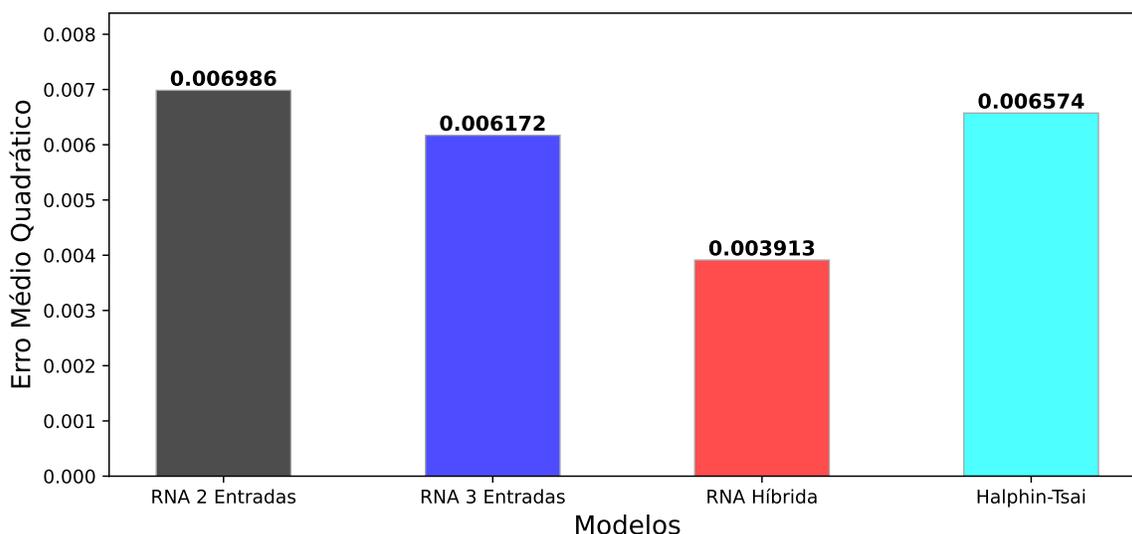
Por meio da tabela 5.1 é possível fazer uma análise comparativa de todos os modelos descritos nos itens anteriores. O modelo de RNA três entradas e o modelo misto alcançaram os melhores resultados, já o modelo de RNA duas entradas obteve resultados insatisfatórios e piores do que o modelo de Halpin-Tsai. Pode-se ser observado ainda que o EMQ do modelo misto é menor do que o de todos os outros modelos, com um valor aproximadamente 36.6% menor do que o do modelo de três entradas. A diferença entre estes resultados é melhor exemplificada na Figura 5.7 que demonstra um gráfico de barras com os valores de erro médio quadrático. Deve-se comentar que o treinamento desses modelos foi feito sob as mesmas condições e estes valores foram retirados a partir das sessões de treinamento que obtiveram os melhores resultados em relação ao número de neurônios e épocas de treinamento.

Tabela 5.1: Comparativo dos modelos de RNA com o modelo de Halpin-Tsai.

Modelo	EMQ	r	Épocas de Treinamento	Número de Neurônios (Camada oculta)
RNA duas entradas	0.006986	0.9025	5000	12
RNA três entradas	0.006172	0.9358	5000	48
RNA três entradas Híbrida	0.003913	0.9582	5000	24
Halpin-Tsai	0.006574	0.9131	----	----

Fonte: Elaborado pelo autor (2024).

Figura 5.7: Gráfico de barras para análise do EMQ



Fonte: Elaborado pelo autor (2024).

Conclusão

Após a análise dos resultados obtidos, concluímos que o uso de um modelo híbrido (RNA/Halpin-Tsai) produz resultados que habilitam o seu uso para a área de materiais compósitos. Esse modelo se mostra útil no desenvolvimento e teste de módulos de elasticidade transversal de novos compósitos, pois os parâmetros utilizados forneceram resultados superiores aos obtidos isoladamente pelos modelos Halpin-Tsai e outras RNA.

A RNA com duas entradas não atendeu às expectativas, não conseguindo modelar adequadamente o módulo de elasticidade transversal e, portanto, não é confiável para uso. Esse desempenho insatisfatório pode ser atribuído à simplicidade da arquitetura, que não corresponde ao comportamento desejado. O EMQ obtido para o conjunto de dados de teste da RNA de duas entradas foi aproximadamente 0.006986, superior ao modelo de Halpin-Tsai, que alcançou 0.006574, indicando uma performance inferior. Além disso, no início do treinamento não houve uma redução significativa do EMQ do conjunto de treinamento, o que provavelmente resulta em uma RNA incapaz de generalizar e modelar os dados de forma satisfatória.

A RNA com três entradas apresentou resultados mais satisfatórios nas análises qualitativas e quantitativas em comparação com o modelo de Halpin-Tsai. Analisando a curva de erro médio quadrático em função do número de épocas de treinamento, percebeu-se que houve um acompanhamento das duas curvas na mesma ordem de grandeza, sugerindo uma melhor generalização do comportamento micromecânico.

A RNA de três entradas alcançou resultados significativamente melhores que a de duas entradas, com uma melhor distribuição dos valores de E_2 gerados e uma maior aproximação dos valores experimentais.

Na análise comparativa dos valores de E_2 gerados pela RNA de três entradas, os valores mostraram uma boa distribuição para os valores baixos e, para valores mais altos, houve uma melhora em relação à RNA de duas entradas, especialmente nos valores inferiores dos dados experimentais.

Uma diferença crucial entre esses dois tipos de modelamento é que o modelo híbrido generaliza melhor, pois se baseia tanto na RNA quanto nos dados do modelo de Halpin-Tsai. A combinação dos valores das equações semi-empíricas de Halpin-Tsai com a RNA permitiu uma maior aproximação dos resultados experimentais, especialmente nos dados de treinamento. O EMQ do modelo híbrido foi aproximadamente 36.6% menor do que o da RNA de três entradas, demonstrando sua superioridade.

Na análise comparativa dos valores de E_2 gerados pelo modelo híbrido, observa-se uma maior proximidade com os valores reais, principalmente nos dados de treinamento, quando comparado com os outros modelos. Em contraste, a RNA com três entradas, por depender apenas do treinamento do algoritmo, necessita de uma quantidade significativa de dados para obter e apresentar bons resultados.

Portanto, a adoção do modelo híbrido é recomendada para a análise do módulo de elasticidade transversal em materiais compósitos, oferecendo uma abordagem mais robusta e precisa, especialmente em contextos onde os dados disponíveis não são suficientemente extensos.

Referências Bibliográficas

- Affdl, J. H., & Kardos, J. (1976). The halpin-tsai equations: a review. *Polymer Engineering & Science*, 16(5), 344–352.
- Agropecuária, E. I., & GrandelPB, C. (2009). Caracterização química e estrutural de fibra de sisal da variedade agave sisalana.
- Araújo, R. K. F. (2019). Estudo térmico e mecânico de placas cimentícias, simulando uma estrutura de wood frame com uso de vermiculita expandida e fibra de sisal. *Universidade Federal Rural do Semi-Árido*.
- Bank, L. C. (2006). *Composites for construction: structural design with frp materials*. John Wiley & Sons.
- Callister, W. D., & Rethwisch, D. G. (2020). *Fundamentals of materials science and engineering: an integrated approach*. John Wiley & Sons.
- Câmara, E. C. B. (2012). *Previsão do módulo de elasticidade transversal de compósitos unidirecionais através de redes neurais mistas* (Unpublished master's thesis). Universidade Federal do Rio Grande do Norte.
- Câmara, M. (2014). Anatomia e fisiologia humana. *Instituto de Formação–Cursos Técnicos Profissionalizantes*.
- Castro, B. F. M. (2013). *Estudo e caracterização mecânica de compósitos reforçados com fibras naturais* (Unpublished doctoral dissertation). Instituto Politécnico do Porto. Instituto Superior de Engenharia do Porto.
- Cavalcante, M. d. S. (2018). Materiais híbridos orgânicos-inorgânicos: argilominerais, óxidos e polímeros.
- Costa, G. Y. S. C. M., et al. (2021). Aplicação de aprendizado de máquina na predição do rendimento da fermentação de alginase.
- Cunha, J. P. Z. (2019). *Um estudo comparativo das técnicas de validação cruzada aplicadas a modelos mistos* (Unpublished doctoral dissertation). Universidade de São Paulo.
- Dantas, D., Calegario, N., Acerbi, F. W., Carvalho, S. d. P. C., Isaac, M. A., & Melo, E. d. A. (2020). Multilevel nonlinear mixed-effects model and machine learning for predicting the volume of eucalyptus spp. trees. *Cerne*, 26(1), 48–57.

- de Castro, L. A. B., & Grattapaglia, D. (2014). The 5th congress of the brazilian biotechnology society (sbbiotec): Meeting abstracts. In *Bmc proceedings* (Vol. 8, pp. 11–P264).
- de Mendonça, P. d. T. R. (2005). *Materiais compostos e estruturas-sanduiche: projeto e análise*. Manole.
- Diniz, C. A., da Cunha Júnior, S. S., Júnior, A. C. A., Gomes, G. F., Bicalho, R., & Campos, R. B. (2016). Otimização estrutural de elementos em compósitos usando redes neurais artificiais. *Revista Interdisciplinar de Pesquisa em Engenharia*, 2(10), 51–60.
- Eichhorn, S., Hearle, J. W., Jaffe, M., & Kikutani, T. (2009). Handbook of textile fibre structure: Volume 2: Natural, regenerated, inorganic and specialist fibres.
- Fahlman, S. E., et al. (1988). *An empirical study of learning speed in back-propagation networks*. Carnegie Mellon University, Computer Science Department Pittsburgh, PA, USA.
- Faruk, O., Bledzki, A. K., Fink, H.-P., & Sain, M. (2012). Biocomposites reinforced with natural fibers: 2000–2010. *Progress in polymer science*, 37(11), 1552–1596.
- Felipe, R. N. B. (2012). Efeitos da radiação uv, temperatura e vapor aquecido nos compósitos poliméricos: monitoramento, instabilidade estrutural e fratura.
- Ferreira, E. V. (2018). Métodos de reamostragem. *Material de apoio a disciplina de Machine Learning para Cientista de Dados, lecionada na LEG/UFPR*, 16, 17.
- Freire Jr, R. C. S., & Aquino, E. M. F. d. (2005). Fatigue damage mechanism and failure prevention in fiberglass reinforced plastic. *Materials Research*, 8, 45–49.
- Géron, A. (2019). *Mãos à obra: Aprendizado de máquina com scikit-learn & tensorflow*. Alta Books.
- Godoy, A. P. (2019). Utilização de líquidos iônicos na esfoliação em fase líquida do grafite e aplicação na formação de nanocompósitos condutores de polímero-grafeno para impressão 3d.
- Goleman, D. (2017). *Inteligência ecológica: o impacto do que consumimos e as mudanças que podem melhorar o planeta*. Elsevier Brasil.
- Halpin, J. C., & Tsai, S. (1969). Effects of environmental factors on composite materials.
- Haykin, S. (2001). *Redes neurais: princípios e prática*. Bookman Editora.
- Ishizaki, M. H., Visconte, L. L., Furtado, C. R., Leite, M. C., & Leblanc, J. L. (2006). Caracterização mecânica e morfológica de compósitos de polipropileno e fibras de coco verde: influência do teor de fibra e das condições de mistura. *Polímeros*, 16, 182–186.
- Júnior, R. C. S. F., Neto, A. D. D., & de Aquino, E. M. F. (2005). Building of constant life diagrams of fatigue using artificial neural networks. *International Journal of Fatigue*, 27(7), 746–751.
- Kaw, A. K. (2005). *Mechanics of composite materials*. CRC press.
- Kumaresan, M., Sathish, S., Karthi, N., et al. (2015). Effect of fiber orientation on mechanical

- properties of sisal fiber reinforced epoxy composites. *Journal of Applied Science and Engineering*, 18(3), 289–294.
- Leal, M. d. O. C. D. (2019). *Estimativa do sexo em amostras brasileiras com validação cruzada em populações de diferentes regiões* (Unpublished doctoral dissertation). [sn].
- Leão, J. F. A. (2018). Critérios de falha e modelos analíticos para análise local em dutos flexíveis com armaduras de tração em material compósito.
- Leão, M. A. (2013). Compósitos poliméricos a base de fibras de licuri: efeitos da hibridização e do envelhecimento ambiental acelerado.
- Lemos, A. L. d., & Martins, R. M. d. (2014). Desenvolvimento e caracterização de compósitos poliméricos à base de poli (ácido láctico) e fibras naturais. *Polímeros*, 24, 190–197.
- Líbano, E. V. D. G., da Costa Pereira, P. S., Bastos, D. C., de Souza Coelho, K. V., et al. (2020). Estudo da influência do teor de fibras e de compatibilizante na obtenção de compósitos de polietileno de alta densidade pós-consumo (peadpc) com fibras de bagaço de cana-de-açúcar (bca). *Cadernos UniFOA*, 15(43).
- Lima, M. P. S. d. (2021). *Avaliação de estratégias de decisão de mobilidade madm orientados para a qualidade em cenário de redes 5g* (Unpublished master's thesis). Universidade Federal do Rio Grande do Norte.
- Lopes, V. H. S. (2024). Análise comparativa do pré-processamento de dados na classificação de sementes.
- Lorandi, N. P., Cioffi, M. O. H., & Ornaghi Jr, H. (2016). Análise dinâmico-mecânica de materiais compósitos poliméricos. *Sci Cum Ind*, 4(13), 48–60.
- Martin, A. R., Martins, M. A., Mattoso, L. H., & Silva, O. R. (2009). Caracterização química e estrutural de fibra de sisal da variedade agave sisalana. *Polímeros*, 19, 40–46.
- Martins, G. S., Iozzi, M. A., Martins, M. A., Mattoso, L. H., & Ferreira, F. C. (2004). Caracterização mecânica e térmica de compósitos de poli (cloreto de vinila) reforçados com fibras de sisal. *Polímeros*, 14, 326–333.
- Møller, M. F. (1993). A scaled conjugate gradient algorithm for fast supervised learning. *Neural networks*, 6(4), 525–533.
- Monteiro, S. N., Rodriguez, R. J. S., Lopes, F. P. D., & Sores, B. G. (2013). Efeito da incorporação de fibras de coco no comportamento dinâmico-mecânico de compósitos com matriz poliéster. *Tecnologia em Metalurgia, Materiais e Mineração*, 5(2), 111–115.
- Mwaikambo, L. (2006). Review of the history, properties and application of plant fibres. *African Journal of Science and Technology*, 7(2), 121.
- Nascimento, G., Silva, S., Dias, R., Gomes, I., & Fujiyama. (2019). Estudo e comparação entre compósitos reforçados com fibras naturais, fibras de vidro e híbridos.
- Neto, F. L., & Pardini, L. C. (2016). *Compósitos estruturais: ciência e tecnologia*. Editora Blucher.

- Oliveira, G. A. B. (2018). *Predição de propriedades mecânicas de compósitos unidirecionais através de redes neurais artificiais* (Unpublished master's thesis). Brasil.
- Paixão, R. C. F. d., Penido, R. E.-K., Cury, A. A., & Mendes, J. C. (2022). Comparison of machine learning techniques to predict the compressive strength of concrete and considerations on model generalization. *Revista IBRACON de Estruturas e Materiais*, 15(5), e15503.
- Passatore, C. R. (2013). Química dos polímeros. *Material didático, 3º módulo*.
- Pezzolo, D. B. (2019). *Tecidos: história, tramas, tipos e usos*. Editora Senac São Paulo.
- Pinto, M. R. O., A Júnior, M. M., Carvalho, L. H., et al. (2005). Influência da adição e da modificação química de uma carga mineral nanoparticulada nas propriedades mecânicas e no envelhecimento térmico de compósitos poliuretano/sisal. *Polímeros*, 15, 313–319.
- Prasad, G. E., Gowda, B. K., & Velmurugan, R. (2017). Comparative study of impact strength characteristics of treated and untreated sisal polyester composites. *Procedia Engineering*, 173, 778–785.
- Recicar, G. L. (2022). Efeito dos processos de laminação manual e laminação termomecânica nas propriedades mecânicas de material compósito carbono-epóxi.
- Riedmiller, M., & Braun, H. (1993). *A direct adaptive method for faster backpropagation learning: The rprop algorithm*.
- Romão, C. M. N. (2003). Estudo do comportamento mecânico de materiais compósitos de matriz polimérica reforçados com fibras naturais.
- Rusell, S. J., & Norvig, P. (2013). *Inteligência artificial. tradução regina célia simille*. Rio de Janeiro: Elsevier.
- Schelb, C. G. (2016). Avaliação de tipologias construtivas nos critérios de sustentabilidade: estudo de casos–telhas.
- Shepherd, G. M. (2003). *The synaptic organization of the brain*. Oxford university press.
- Silva, A. d. N. (2017). Utilização de algoritmo com rede neural artificial na validação de padrões de comportamento do c. elegans.
- Silva, A. P. d. O., Quaresma, S., Motta, L., & Francklin, H. (2015). Estudo das propriedades mecânicas de compósitos de matriz epóxi reforçada com fibras de sisal para reforço de estruturas de concreto. In *13º congresso brasileiro de polímeros, natal*.
- SILVA, M., P. H. F. (2001). *Fast and accurate neural network gaas mesfet model for time-domain circuit simulation* (Vol. 1).
- Silva, S., de Oliveira Neto, S. N., Leite, H. G., de Alcântara, A. E. M., de Oliveira Neto, R. R., & de Souza, G. S. A. (2020). Productivity estimate using regression and artificial neural networks in small familiar areas with agrosilvopastoral systems. *Agroforestry Systems*, 94, 2081–2097.
- Silva, S. O. (2021). Controle de qualidade e desempenho de préimpregnados fibra natu-



ral/epóxi para a produção de compósitos.

Silva, T. L. S., de Oliveira Filho, G. C., & do Nascimento Silva., A. (2024). Finite element analysis of polymeric matrix composites with sisal fiber reinforcement. *JBTH*, 6(Suppl2), 38–43.

Vasconcelos, J. V. d. B. V. (2013). *Estudo de soluções de baixo impacto ambiental para revestimento têxtil* (Unpublished doctoral dissertation).

Vasiliev, V. V., & Morozov, E. V. (2001). *Mechanics and analysis of composite materials*. Elsevier.

Watt, J. P., Davies, G. F., & O'Connell, R. J. (1976). The elastic properties of composite materials. *Reviews of Geophysics*, 14(4), 541–563.