

Desenvolvimento de Algoritmos baseados em Inteligência Artificial para manipulação de funções e comparação com as técnicas numéricas utilizadas nas Engenharias

Elias R. Gonçalves Júnior¹, Caio L. Nunes¹, Virgínia S. Gonçalves¹

¹Universidade Candido Mendes - Campos (UCAM-Campos)
CEP 28030-335 – Campos dos Goytacazes – RJ – Brasil

eliasrgjunior1@gmail.com, caioln92@gmail.com,
virgíniaisqueiragoncalves@gmail.com

Abstract. *This paper aims to develop and test the efficiency of some applications of artificial intelligence algorithms and to compare them to the numerical techniques used in the engineering areas, from the use of neural network structures to approximate functions. To this end, it was made functions' modeling, which are not governed by simple formulas, what makes the need to be approximate. The neural networks can solve problems in this type with accuracy, being this is the statement investigated during the study of this paper. As a test, an approximation of the measurements of thermodynamic tables (saturated water) is carried out and it's checked and compared the results with numerical traditional methods (linear functions splines and quadratic function), checking the efficiency and the possibility of its use*

Resumo. *Este trabalho visa desenvolver e testar a eficiência de algumas aplicações dos algoritmos de inteligência artificial e compará-las às técnicas numéricas utilizadas nas áreas da engenharia, a partir da utilização de estruturas de redes neurais para aproximação de funções. Para tal, foi realizada a modelagem de funções, as quais não são regidas por fórmulas simples, o que faz necessário serem aproximadas. As redes neurais conseguem resolver com boa exatidão problemas desse tipo, sendo esta a questão investigada durante o estudo deste trabalho. Como teste, é realizada uma aproximação das medições das tabelas de termodinâmica (água saturada) e é verificado e comparado o resultado com métodos numéricos tradicionais (funções splines lineares e quadráticas), checando a eficiência e possibilidade de seu uso.*

1. Introdução

A inteligência artificial (IA) consiste em retirar informações do ambiente onde está embutida e utilizá-las para resolver determinados problemas, como uma espécie de aprendizado. Dessa forma, ela se torna versátil para ser incluída em diversas áreas do conhecimento, como as engenharias [SILVA *et al.*, 2010]. Segundo Heckmann (1999), inteligência artificial é a ciência de fazer o computador realizar tarefas que, até agora, somente as pessoas podiam realizar e somente pessoas muito especializadas podiam realizar bem.

A engenharia está visível em todas as partes, seus campos de operação são extremamente abrangentes, podendo atuar desde pequenos projetos de tubulações domésticas até grandes indústrias petrolíferas. Com a evolução da tecnologia, o engenheiro obteve formas mais eficientes e rápidas de efetuar cálculos matemáticos por meio do computador. Este, por sua vez, consegue atingir patamares cada vez mais elevados para a resolução de problemas matemáticos. Portanto, é necessário que existam engenheiros capazes de dominar a informática, pois a integração desses campos pode ser muito eficaz na resolução de problemas.

A IA se mostra uma alternativa eficiente a ser estudada. Entre as suas capacidades estão problemas envolvendo aproximação e modelagem de funções, que podem ser aplicadas nas áreas da termodinâmica e resolução de problemas de otimização de funções com várias variáveis e restrições comuns na área de projetos [HECKMANN, 1999].

Nesta pesquisa, será feita uma comparação entre o método de aproximação de funções obtido por meio das redes neurais artificiais e pelos métodos advindos do cálculo numérico, como a interpolação e funções *spline*¹. Como objeto, serão utilizadas as tabelas de termodinâmica para encontrar uma função que aproxime seu comportamento. Tais tabelas não são regidas por uma função, sendo necessário aproximar os valores não tabelados para a utilização em problemas específicos.

O objetivo deste trabalho é desenvolver algoritmos que possam testar as técnicas de inteligência artificial (redes neurais) e comparar sua eficiência prática com as técnicas numéricas (interpolações), para verificar a possibilidade de sua implementação na resolução de problemas comuns na engenharia mecânica. Serão feitos experimentos simples utilizando algoritmos computacionais, onde será possível calcular sua eficiência em relação a outros métodos.

2. Referencial Teórico

2.1. Interpolação Linear

A interpolação linear é o caso mais simples e também o mais utilizado. Dados dois pontos distintos de uma função, deve ser construído um polinômio de grau um $P_1(x) = a_0 + a_1x$, tal que tenha que satisfazer o sistema da equação, representada na Figura 1, na qual geometricamente $P_1(x)$ é a equação da reta que passa por entre os dois pontos x_0 e x_1 [BALBO, 2007].

$$\begin{cases} P_1(x_0) = f(x_0) = y_0 \\ P_1(x_1) = f(x_1) = y_1 \end{cases}$$

Figura 1. Sistema para interpolação linear

As funções interpolantes sempre passam pelos pontos conhecidos da função original e, a partir deles, são estimados os valores não conhecidos. Sendo $f(x)$ a função original e $g(x)$ a aproximação, pode ser percebido que a distância entre elas aumenta quando estão mais distantes dos pontos utilizados na interpolação. Essa distância é a que define o erro [RUGGIERO & LOPES, 1996].

¹ Função definida segmentarmente por polinômios (no sentido lato) [Paulino *et. al.*, 2011].

A Figura 2 mostra um exemplo de gráfico entre a função original e sua interpolante, sendo conhecidos apenas 5 pontos.

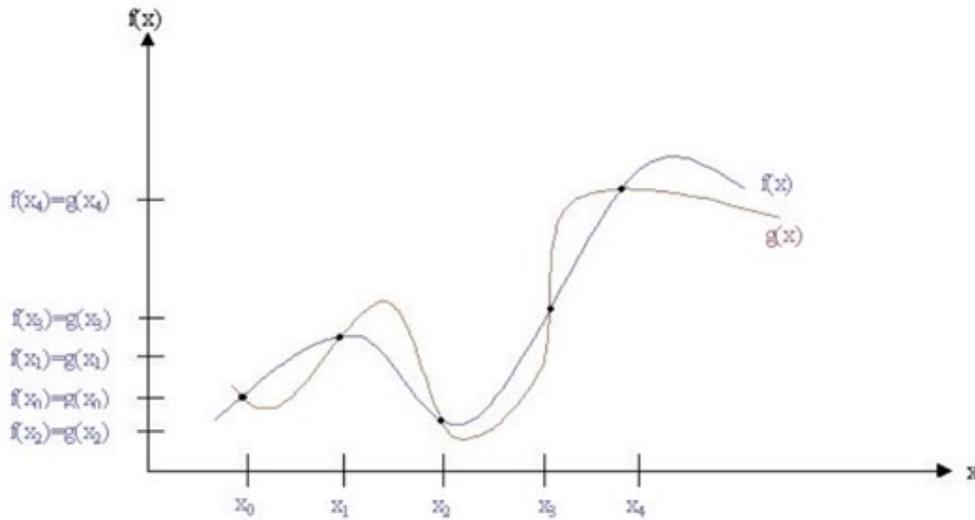


Figura 2. Gráfico utilizando polinômio interpolador

Em aspectos práticos, raramente é utilizada interpolação sobre funções com mais do que seis pontos, pelo fato de o erro aumentar demasiadamente, passando-se, assim, para os splines nos restantes casos. Os splines são utilizados para conseguir a redução da ordem da função aproximante. O método utilizado para esta aproximação alternativa consiste em ajustar polinômios de ordem mais baixa a subconjuntos dos dados. Tais polinômios de ligação são chamados funções splines [RUGGIERO e LOPES, 1996].

Polinômios com ordem alta tendem a não captar mudanças bruscas no comportamento da função. Assim as splines conseguem melhor aproximação em funções com esse tipo de característica [PILLING, 2009].

2.2. Redes Neurais: aprendizado e implementação

A característica principal das redes neurais é a sua capacidade de adaptação e generalização. Esse atributo é adquirido alterando seus pesos sinápticos de tal forma que minimize o erro da saída da rede, até que seja alcançada uma solução ótima. Para alcançar tal solução, são utilizados algoritmos de treinamento característicos de cada uma das arquiteturas de redes neurais. O *Multilayer Perceptron* utiliza o algoritmo *Backpropagation* (ou variações) para seu treinamento [HECKMANN, 1999].

Para este trabalho, será utilizada a rede *Multilayer Perceptron* (MLP). Alguns aspectos sobre sua utilização ainda precisam ser discutidos, como a topologia, o tipo de treinamento, problemas a serem evitados e a organização dos conjuntos de treinamento.

2.3. Tabelas Termodinâmicas

A compreensão destas tabelas é muito importante para o desenvolvimento acadêmico do engenheiro mecânico, pois elas são indispensáveis quando se trabalha com vapor ou ciclos termodinâmicos. Podem ser apresentados valores de temperatura e pressão em três situações: líquido comprimido, vapor superaquecido ou saturado. [VAN WYLEN e SONNTAG, 2009].

As tabelas têm riqueza de detalhes, pequena taxa de erro do valor real dos compostos e vários valores de temperatura versus pressão já tabelados, além de ser frequentemente utilizada com a interpolação linear por estudantes das engenharias. Com essas características, as tabelas se apresentam como uma boa opção para serem utilizadas nos testes dos métodos de aproximação, pois, além de apresentarem valores práticos, também mostram simplicidade na sua manipulação [VAN WYLEN e SONNTAG, 2009].

A partir destas tabelas, serão utilizados os métodos de interpolação (spline linear e quadrática) e a aproximação utilizando redes neurais. A tabela de água saturada completa é composta por 79 amostras e entre cada amostra há um intervalo que necessita de aproximação.

3. Metodologia

Por meio dos testes dos métodos estudados neste trabalho, foram desenvolvidos algoritmos computacionais escritos em linguagem C e para geração de gráficos a plataforma de cálculos matemáticos Matlab, por meio dos quais é possível obter melhor visualização e análise dos resultados.

Todos os códigos utilizados nesta pesquisa são de autoria própria e estão disponíveis para acesso no link “<https://github.com/Eliasrgjunior1/CITI2017-1/blob/master/README.md>”, não sendo utilizados partes/adaptações de outros autores ou programas já prontos. Seu desenvolvimento foi baseado nas técnicas descritas durante a revisão de literatura, ressaltando os fundamentos da IA.

Para o caso de aproximação de funções, foram utilizadas como objeto as tabelas de termodinâmica (água vapor saturado), em que foram feitos os cálculos usando interpolação (linear, quadrática e funções spline) e as redes neurais. Uma rotina foi gerada, utilizando o Matlab, no qual o gráfico de cada função gerada por cada um dos métodos poderá ser plotado. Para a modelagem das funções, foram selecionadas 46 amostras da tabela de forma aleatória para o treinamento das Redes Neurais (NN – *Neural Networks*) e para as interpolações. O cálculo da eficiência de cada técnica foi efetuado utilizando as 33 amostras não utilizadas. Comparando os valores obtidos com o valor real medido, foi possível estimar o erro de ambos os métodos, definindo assim o mais eficiente nesse contexto.

Para cada caso nos quais foram utilizadas redes neurais, suas estruturas foram feitas na arquitetura do Multilayer Perceptron (MLP) e seu treinamento foi o Levenberg Maquardt (LM), em que poderão ser variadas as topologias utilizadas para melhorar a fidelidade dos resultados.

A partir desses métodos, este trabalho buscará obter as conclusões desejadas sobre as possibilidades de aplicações de redes neurais na mecânica, sua eficiência e a facilidade dos projetos.

3.1. Preparação dos dados

Para que os dados estivessem adequados para a realização dos testes, foram realizadas as seguintes etapas:

- Montagem do arquivo contendo os valores a serem utilizados a partir das tabelas termodinâmicas de água saturada, destacando valores de pressão e entalpia;

- Desenvolvimento da rotina para o Matlab plotar gráficos com dados extraídos das execuções dos algoritmos desenvolvidos. Estes serão plotados gráficos em duas dimensões com a pressão em relação à temperatura;

- Plotagem dos pontos já tabelados, para visualização limpa da tabela.

3.2. Programação dos algoritmos

Nesta fase, foram realizadas as seguintes ações:

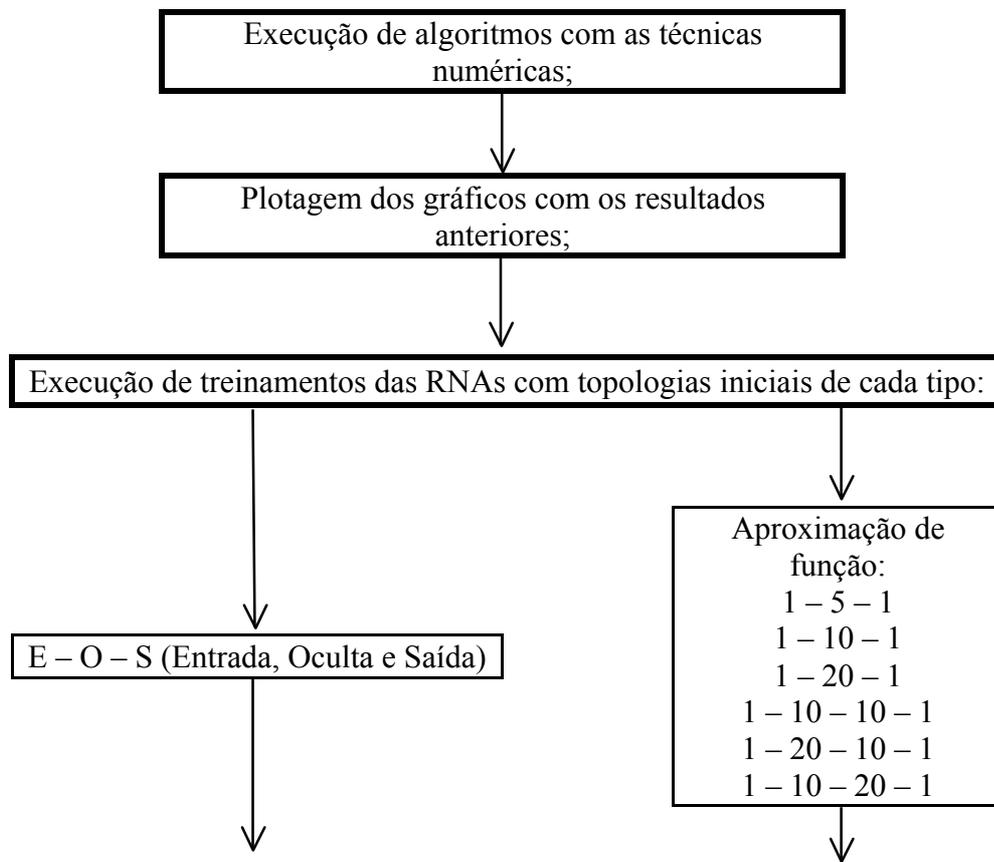
- Desenvolvimento de algoritmo de rede neural artificial (RNA) através do MatLab®, com uma camada escondida, e treinamento LM. O algoritmo deverá ser capaz de alterar o número de neurônios na camada oculta, para a realização do teste com diversas topologias;

- Desenvolvimento de algoritmo para interpolação linear numérica utilizando splines;

- Desenvolvimento de algoritmo para interpolação, utilizando funções spline quadráticas, que devem receber o número de pontos e os dados da tabela necessários para aproximar a função.

3.3. Fase de testes

Os testes seguiram os procedimentos definidos pelo fluxograma abaixo:



Verificação dos resultados dos treinamentos (capacidade de generalização e discrepância com os gráficos obtidos a partir das técnicas numéricas).
Em caso de resultados insatisfatórios, refazer treinamentos com novas topologias. Se ainda for insatisfatório, utilizar as topologias com resultados melhores;

Execução das RNAs treinadas e geração de resultados;

Plotagem de todos os gráficos utilizando o Matlab;

Compilação dos dados obtidos em tabelas.

4. Resultados e Discussões

4.1. Tabela Termodinâmica de Água Saturada

Os gráficos das tabelas de termodinâmica obedecem a um determinado padrão, que deve ser aprendido pelas RNAs. Para validação, os pontos da tabela foram colocados de maneira ordenada, gerando o gráfico abaixo (vide Figura 3):

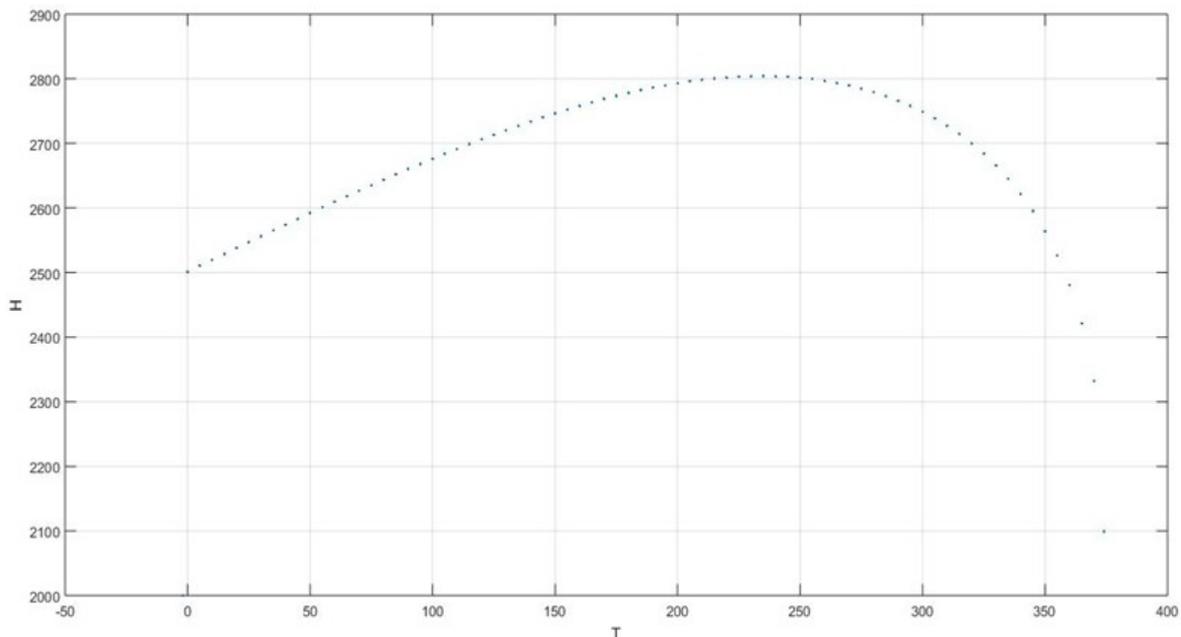


Figura 3. Gráfico temperatura (°C) x entalpia (kJ/kg)

4.2. Cálculo de dispersão

Os algoritmos para fazer as interpolações funcionaram de forma esperada, modelando a função com baixo erro. A partir das redes neurais treinadas e das interpolações, foram

obtidas as aproximações para os valores desejados. Como resultado, foram calculados a variância e o desvio padrão (vide Quadro 1).

Quadro 1. Resultado dos cálculos de desvio padrão e variância - temperatura x entalpia

TxH		
	Desvio Padrão	Variância
Interpolação Linear	0,35438	0,125585
Interpolação Quadrática	0,017839	0,000318
NN1	0,829772	0,688521
NN2	0,048836	0,002385
NN3	0,144406	0,020853
NN4	2,231818	4,98101
NN5	1,231894	1,520028
NN6	4,299726	18,487644

4.3. Análise dos gráficos de aproximação

Os algoritmos utilizados nas interpolações funcionaram de forma esperada, modelando a função com baixo erro. A partir das redes neurais treinadas e das interpolações, foram obtidas as aproximações para os valores desejados.

Foram plotados gráficos para comparação entre as NN de 1 ou 2 camadas e as interpolações. Pode ser visualizada melhor a eficiência obtida pelos gráficos. As figuras 4 e 5 mostram os gráficos das NN combinadas e pontos de interesse. Já a figura 6, demonstra os valores obtidos pelas interpolações polinomiais.

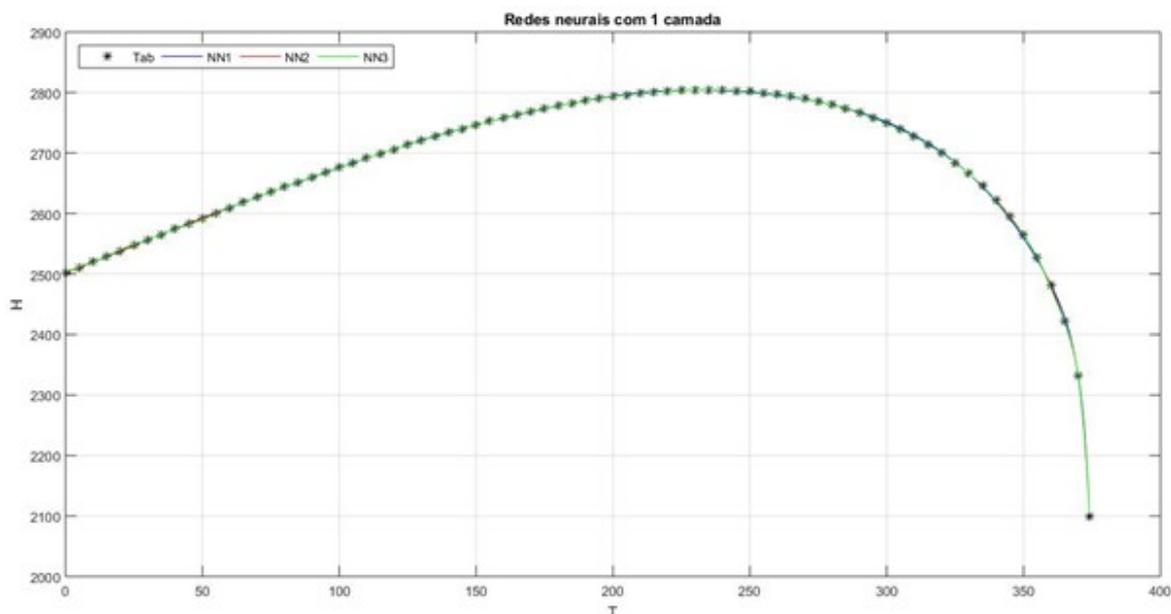


Figura 4. Gráfico temperatura x entalpia - aproximação com NN de 1 camada oculta

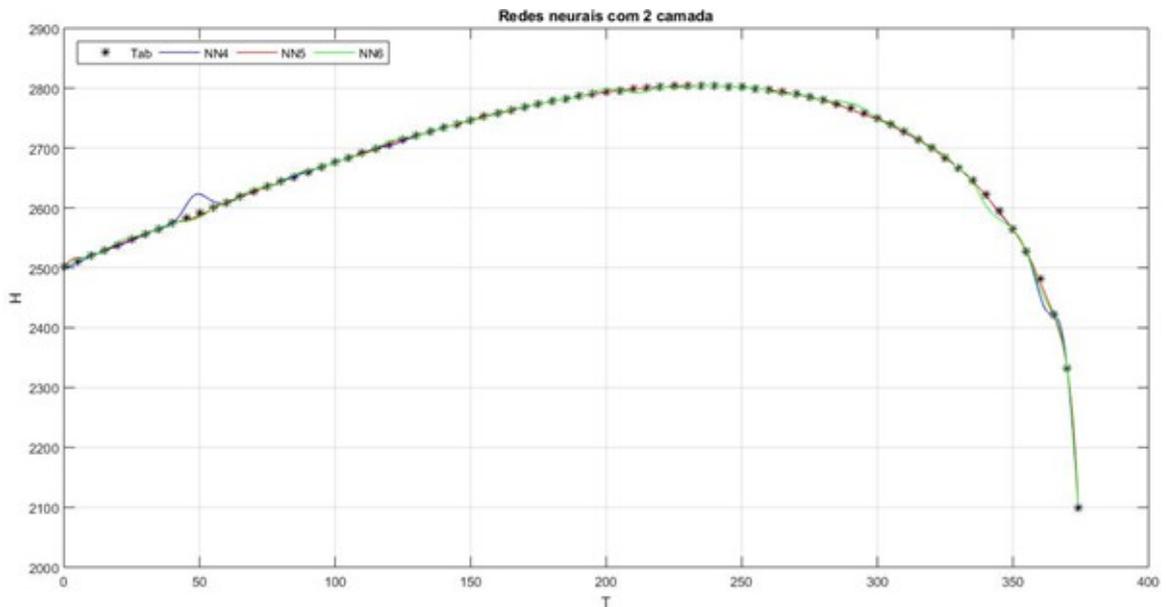


Figura 5. Gráfico temperatura (°C) x entalpia (kJ/kg) - aproximação com NN de 2 camadas oculta

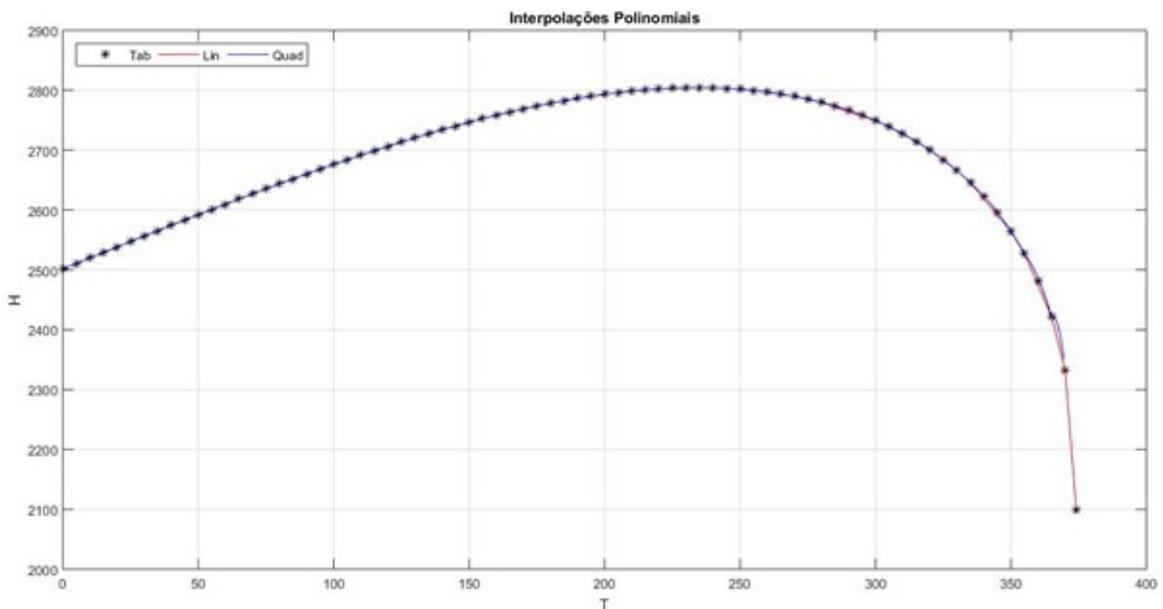


Figura 6. Gráfico temperatura (°C) x entalpia (kJ/kg) - aproximação com interações polinomiais

Por fim, para efeito de comparação, foi plotado o gráfico combinado dos valores pelas redes neurais e pelo processo de interpolação polinomial e as interpolações. A figura 7 abaixo ilustra o mesmo.

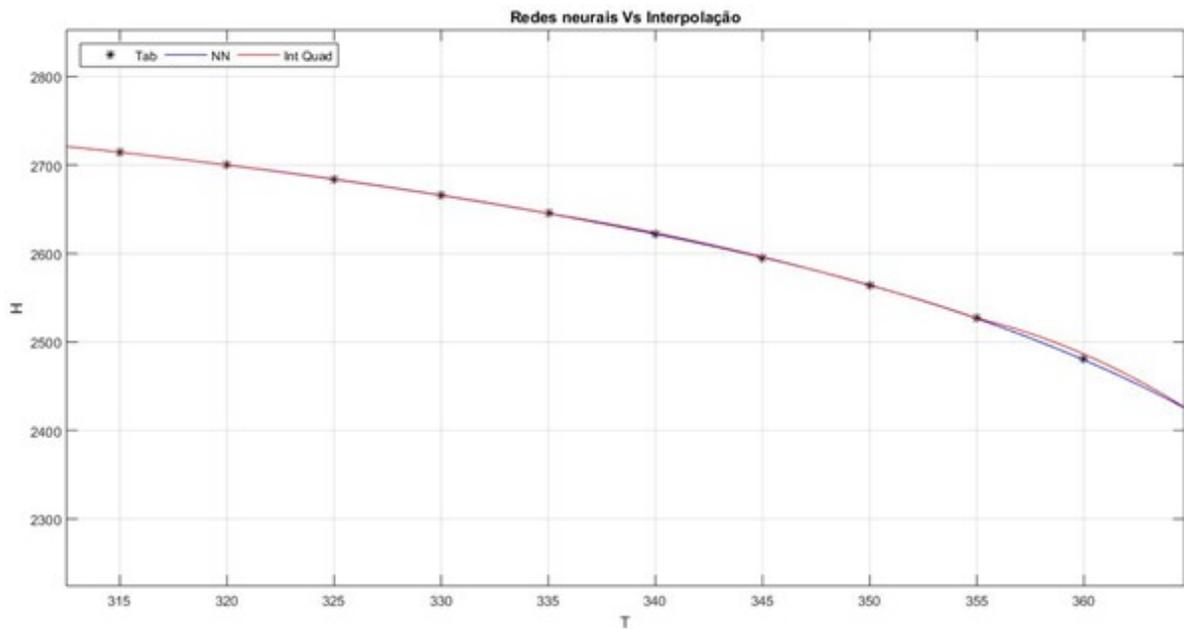


Figura 7. Gráfico temperatura (°C) x entalpia (kJ/kg) comparando valores obtidos pelas técnicas utilizadas de aproximação

Os gráficos conseguem exibir o resultado das aproximações, utilizando todos os pontos. As redes neurais não se comportam de forma exata, podendo haver erros, inclusive nos pontos que foram utilizados para o treinamento. É importante ressaltar que esse comportamento não ocorre nas interpolações, pois com um treinamento eficiente é possível eliminar esse tipo de erro. Há também um comportamento homogêneo em toda a função, onde os erros não são aumentados em pontos específicos, comparando com as interpolações, apresentam aproximação mais eficiente desses pontos.

É possível observar, pelos gráficos obtidos da tabela utilizada, que ela forma uma função contínua sem grande aleatoriedade. Este é o melhor cenário para aplicação das interpolações linear e quadrática. Para situações nas quais não é necessária alta precisão, a interpolação linear seria a ideal, pois é de simples execução, porém, para aplicações de alta precisão, os métodos devem ser comparados.

Em todos os ensaios, a configuração da rede neural número 2 conseguiu se destacar sobre as outras, logo esta será o padrão para a comparação.

Pode-se observar também que a interpolação linear deixa a desejar nos trechos onde a função forma uma curva de maior inclinação, fazendo com que o erro, em alguns casos, aumente consideravelmente. A curva obtida pela interpolação quadrática aumenta o erro apenas quando os pontos não estão dispostos simetricamente, o que faz com que ela não aproxime a função satisfatoriamente.

A NN deve ter seu treinamento feito meticulosamente para ser obtido um resultado eficiente. Algumas configurações apresentam erro bem alto em comparação com as outras, porém o resultado final obtido foi mais preciso que a interpolação quadrática. As dispersões da NN foram menores ou iguais em todas as situações, como foi exibido nas tabelas.

A partir do treinamento, pode ser observado que o erro necessário para este tipo de função é da ordem de $10e-2$, erros menores configuram sobre treino, que é o caso das redes neurais de duas camadas. Além disso, é possível concluir que, para funções de baixa complexidade, NN mais simples, com uma camada e poucos neurônios, são mais eficientes para esse objetivo. O treinamento com poucas amostras (relativamente para NN) foi possível e as redes neurais se adaptaram sem grandes dificuldades.

5. Conclusão

Sabendo que as redes neurais conseguem atingir desempenho superior às interpolações, mesmo em funções padrão e apresentam baixa aleatoriedade, pode-se afirmar que elas podem ser utilizadas para completar tabelas de medição (como as termodinâmicas), se adaptar a funções de descrição de respostas de sistemas de controle, desenho vetorial em softwares especializados, como o Matlab, e auxiliar em estudos de fenômenos físicos. Além dos termodinâmicos para descrição de funções, e ainda auxiliar na resolução e desenvolvimento de projetos específicos para engenharia.

As topologias das NN mais eficientes aqui presentes podem ser tomadas como ponto de partida de trabalhos similares, o treinamento descrito pode ser utilizado em outros problemas. As redes neurais também podem ser utilizadas em casos em que há solução matemática funcional, como esse, e apresentar resultado similar ou mais eficiente, desde que seja seguida a rotina de treinamento adequada.

Podem ser exploradas, a partir desses resultados, algumas novas comparações das ferramentas de cálculo numérico, como a extrapolação e algumas aplicações da modelagem de funções matemáticas de difícil cálculo, além de poder executar comparações entre outras variáveis presentes nas tabelas de termodinâmica.

Referências

- Balbo, A. R. Aproximação de funções. UNESP. São Paulo, p. 78. 2007.
- Paulino, C. D.; Pestana, D.; Branco, J.; Singer, J.; Barroso, L.; Bussab, W. Glossário Inglês-Português de Estatística. 2a ed. Sociedade Portuguesa de Estatística e Associação Brasileira de Estatística. 2011.
- Heckmann, J. R. "Identificação de Potenciais Aplicações da Inteligência Artificial na Metrologia". UFSC. Florianópolis, p. 142. 1999.
- Pilling, S. Cálculo Numérico. FEAU. São José dos campos, p. 13. 2009.
- Ruggiero, M. A. R.; Lopes, V. L. R. Cálculo numérico: aspectos teóricos e computacionais. 2. ed. são paulo: Pearson Makron Books., v. 1, 1996.
- Silva, I. N. D. *et. al.* Redes Neurais Artificiais para engenharia e ciências aplicadas. 1. ed. São Paulo: Artliber, v. 1, 2010.
- Van Wylen, G.; Sonntag, R. E. Fundamentos da Termodinâmica. 7. ed. [S.l.]: Blucher, v. 1, 2009