

Avaliação do uso de redes neurais artificiais para a determinação do carregamento de produtos em refrigeradores domésticos – EVR2021-015

Henrique J. A. Altoé¹, Luiza A. Cordeiro^{1,*}, Antônio A. T. Maia¹

¹ Universidade Federal de Minas Gerais, Departamento de Engenharia Mecânica, Laboratório de Automação e Controle
Belo Horizonte, Minas Gerais, Brasil, 31270-901

* Autor para correspondência, luizaaraujocordeiro@gmail.com

Resumo

O elevado consumo energético doméstico causado pelos refrigeradores torna fundamental a busca pelo aumento da eficiência de tais equipamentos. O carregamento de produtos no seu interior influencia diretamente a operação e normalmente não é considerado na definição do ajuste da temperatura interna. Um ajuste inadequado pode resultar em uma temperatura interna inapropriada para a conservação dos alimentos e/ou um consumo de energia maior do que o necessário para uma dada condição de carregamento. Neste contexto, propõe-se neste trabalho o desenvolvimento de redes neurais artificiais para prever o carregamento a partir da medição da temperatura interna durante os ciclos de operação do refrigerador. Foi treinada uma rede neural para classificar o carregamento entre 0, 10, 20 ou 30 caixas e outra para regressão, que retornou um valor contínuo entre 0 e 30 caixas. Utilizando a média dos dados de treinamento como entrada, obteve-se um erro médio de 0,33 caixas com a rede de regressão, e com a rede de classificação todas as saídas foram corretamente classificadas, sendo o menor valor correto encontrado como 88% de probabilidade. Foram utilizados dados interpolados entre as médias de dados de treinamento como novas entradas para carregamentos intermediários de 5, 15, 25 e extrapolado para 35 caixas. A rede de regressão obteve erro médio de 1,2 caixas para os valores interpolados e aproximadamente 5 caixas para o caso extrapolado. Conclui-se que ambas as redes podem ser utilizadas para o problema proposto.

Palavras-chave: refrigeração, redução de consumo, carregamento de produto, redes neurais artificiais

Introdução

Muitas pesquisas já foram realizadas para identificar os fatores que mais influenciam o consumo do refrigerador. Saidur (2002) avaliou o impacto da temperatura ambiente, aberturas de portas e posição do termostato no seu funcionamento. Murta (2015) avaliou o impacto da carga térmica e das posições do termostato no consumo. França (2015) relacionou a carga térmica com a resposta dinâmica do refrigerador doméstico.

O interesse em reduzir o consumo dos refrigeradores domésticos é justificado por sua ampla aplicação. De acordo com o IBGE (2019), 98,1% das residências brasileiras possuem ao menos uma geladeira. Esse aparelho pode ser responsável até por 45% do consumo de energia domiciliar no verão (Fedrigo, 2007). Assim, qualquer redução no consumo desses equipamentos causa um grande impacto no consumo total de energia do país.

Hoje, no Brasil, a maioria das geladeiras domésticas opera em um ciclo de compressão de vapor e seu controle baseia-se em um sistema *on/off* (liga/desliga), o que torna interessante propor melhorias que sejam aplicáveis a esse tipo de sistema. A partida e a parada do compressor são comandadas por um termostato que pode ser ajustado pelo usuário conforme as condições de uso, determinando as temperaturas máxima e mínima do ciclo em operação. O funcionamento do ciclo será afetado principalmente pelo carregamento de produto em seu interior, temperatura ambiente e quantidade de aberturas de porta (Murta, 2015; Saidur, 2002).

A partir do carregamento presente no interior do refrigerador doméstico, o termostato pode ser ajustado de forma a manter uma temperatura máxima aceitável para a conservação dos alimentos no interior do refrigerador e, ao mesmo tempo, minimizar o consumo de energia elétrica pelo aparelho. Tendo isso em vista, o objetivo do trabalho é desenvolver e avaliar a aplicação de redes neurais para determinação do carregamento de produtos do refrigerador, a partir de dados de tempos de ciclos de funcionamento do equipamento.

Metodologia

Para a realização dos testes experimentais, utilizou-se um refrigerador doméstico comum Consul CRC28EBANA de 280 litros. O termostato da geladeira foi substituído por um controlador liga/desliga implementado utilizando o microcontrolador ATmega328 com um relé ligado ao compressor e um sensor encapsulado DS18B20 posicionado no interior do compartimento do congelador. Essa substituição foi feita porque os limites de temperatura definidos pelo termostato não permanecem dentro dos mesmos limites de temperatura ao longo dos testes (França, 2015).

O refrigerador foi posicionado no centro de uma sala fechada de 1,5 m x 2 m, dotada de sistemas para refrigeração, aquecimento e medição de temperaturas. A temperatura da sala foi controlada através da média de três sensores, posicionados a 1 m de altura do chão e 50 cm das laterais e da porta da geladeira, conforme determinado pela norma ISO 8187.

Para realização do treinamento da rede, foi necessário inicialmente obter dados do funcionamento do refrigerador durante sua operação sob diferentes condições de trabalho. Cada teste consistiu em inserir diferentes cargas de produto no interior do refrigerador e colocá-lo em funcionamento até que atingisse o regime quase permanente, caracterizado por valores estáveis para as temperaturas máximas e mínimas obtidas durante os ciclos de operação. Os testes foram realizados sob diferentes temperaturas ambiente. Os dados em regime quase permanente foram coletados e utilizados posteriormente.

Como cargas de produtos, foram utilizadas caixas de leite de dimensões padronizadas contendo 1 litro de água. O carregamento foi variado em 0, 10, 20 e 30 caixas e elas foram distribuídas no interior do refrigerador de forma uniforme, como exemplificado na Figura 1.



Figura 1: Distribuição de 20 caixas no refrigerador

Conforme estabelecido na norma ISO 8187, a temperatura para a realização dos testes de consumo é de $32 \pm 0,5^\circ\text{C}$. Essa foi a temperatura máxima adotada para realização dos testes. As outras temperaturas ambiente adotadas foram de 27°C , 20°C e $16,5^\circ\text{C}$. Combinando essas temperaturas aos carregamentos, foram realizados 16 testes para coleta de dados, cuja duração foi variada, devido à diferença de tempo para se atingir o regime quase permanente, sendo utilizado no mínimo 48h.

As temperaturas máxima e mínima de operação do refrigerador foram configuradas através do controlador instalado no lugar do termostato. A temperatura máxima configurada, na qual o compressor é ligado, foi de -5°C no interior do congelador, e a de desligamento do compressor foi de -16°C . Esse valor foi utilizado pois, a partir de amplitudes menores, o refrigerador não apresentou comportamento adequado a temperaturas ambiente mais altas, devido à atuação do sistema de proteção do compressor. Para determinar o carregamento a partir dos dados coletados, foram testados dois tipos de metodologia para a rede neural: primeiramente a de classificação e em seguida a de regressão. A rede neural de classificação reconhece o carregamento entre 0, 10, 20 ou 30 caixas, de forma que a saída da rede está relacionada com a probabilidade de se tratar de cada um desses casos. Para o caso de regressão, a saída da rede é um número real de caixas. Para ambas, o comportamento para as médias dos valores de treinamento e também para carregamentos intermediários foi avaliado.

Foram desenvolvidas redes neurais do tipo *feed-forward*, compostas por uma camada de entrada, uma camada oculta e uma de saída. As camadas são constituídas por neurônios

com a função de ativação sigmoide, sendo que a saída dos primeiros se torna a entrada dos próximos. Na Equação 1 (Sá, 2019), a variável y_j refere-se à saída de cada neurônio, $f(\cdot)$ representa a função de ativação, x_i as entradas, w_{ij} os pesos de cada entrada e b_j as *bias*.

$$y_j = f\left(\sum_{i=1}^n x_i w_{ij} + b_j\right) \quad (1)$$

O aprendizado supervisionado foi a forma de treinamento escolhida, uma vez que o problema estudado é estimar o carregamento a partir de dados já rotulados. Como função de custo para quantificar o erro foi utilizada a expressão do somatório dos erros quadrados. O algoritmo de *backpropagation* foi utilizado para ajuste dos pesos no treinamento da rede. Esse método de treinamento foi aplicado junto com o gradiente descendente com momento para minimização da função erro.

A programação da rede neural a ser treinada foi desenvolvida em C++, utilizando o *software* Codeblocks, baseado no código de Bulnaria (2009). Essa linguagem foi escolhida para possibilitar, posteriormente, a implementação da rede obtida em um microcontrolador Atmega328. Isso dispensará o uso do computador para a determinação do carregamento e permitirá a integração do sistema ao refrigerador a um baixo custo.

Os dados coletados foram divididos em duas partes de forma aleatória, sendo 80% utilizada para treinamento e 20% para validação dos resultados.

França (2015) identificou parâmetros importantes na caracterização do carregamento do compressor. Foi observado que o tempo que o compressor fica ligado nos ciclos (t_{on}), tempo que o compressor permanece desligado nos ciclos (t_{off}) e a razão entre eles ($t_r = t_{on}/t_{off}$) seriam bons parâmetros para a caracterização. Como os testes realizados contemplam diferentes temperaturas de trabalho, a temperatura ambiente (T_{amb}) também foi inserida como um parâmetro de entrada, totalizando quatro entradas. A saída é o valor de carregamento. A Figura 2 apresenta um exemplo da variação da temperatura no congelador durante os testes, além dos parâmetros t_{on} e t_{off} coletados.




Figura 2: Operação típica de um refrigerador doméstico e parâmetros coletados

O resultado da rede neural treinada no computador foi transferido para o microcontrolador. Dessa forma, o desempenho do código foi testado, com intuito de avaliar se a capacidade de processamento do sistema seria suficiente.

Foi mensurado o tempo de processamento, que é um parâmetro crítico para possibilitar a aplicação da metodologia em um sistema embarcado de baixo custo.

Para obter os parâmetros de entrada na validação da rede aplicada, foram utilizadas informações de temperatura ambiente dos sensores e informação se o compressor da geladeira estaria ligado ou não, para que através da programação do microcontrolador fosse obtido o t_{on} , t_{off} e t_r além de T_{amb} .

Posteriormente, o comportamento do funcionamento da rede neural para os valores médios dos dados coletados, para valores interpolados entre as médias dos dados e extrapolado além da média dos dados foram analisados.

Resultados e Discussão

Foram coletados 2595 conjuntos de dados nos testes, com cada um deles contendo a temperatura ambiente, o tempo de compressor ligado e o tempo desligado em cada ciclo. Além disso, a razão entre os tempos ligado e desligado foi calculada.

Foi possível observar que os tempos de compressor ligado aumentam com o aumento da temperatura ambiente, enquanto o tempo de compressor desligado diminui, o que era esperado pelo aumento das trocas térmicas com o ambiente. Também se observou que os tempos de compressor ligado e desligado tendem a aumentar com o aumento do número de caixas no interior do refrigerador, já previsto pelo aumento da inércia térmica associada ao carregamento. Com relação à média da razão entre tempos, os valores não apresentaram uma variação significativa com a alteração do carregamento, mas aumentaram com o aumento da temperatura ambiente. Para esses valores de razão de tempos, entre os diferentes carregamentos, obteve-se um desvio padrão relativo máximo de 5,65% para o caso da temperatura externa de 16,5°C.

Com relação aos resultados da rede neural, para ambos os casos, regressão e classificação, foi possível reduzir significativamente o erro durante o treinamento de forma que as redes retornaram corretamente 99% dos dados separados aleatoriamente para validação. Para a rede de regressão, utilizou-se um critério de erro menor do que 0,2 caixas para considerar o valor como correto durante o treinamento.

Os valores médios das entradas de treinamento foram utilizados para avaliar o funcionamento da rede. Como mostrado na Tabela 1, o resultado da rede de classificação foi condizente com o carregamento esperado em caixas em todos os 16 casos. O termo CX foi utilizado para designar o número de caixas. Os resultados são apresentados em forma de percentual, relativos à probabilidade de estar observando cada caso, sendo que o menor valor correto encontrado foi de 88% para o caso de 20°C e 10 caixas e o maior de 100% para os casos de 27°C com 0 caixas e 32°C com 20 caixas. Os resultados foram satisfatórios e classificam corretamente todos os casos de acordo com o esperado.

A rede de regressão retornou com sucesso todos os casos, conforme apresentado pela Tabela 2. O erro máximo encontrado foi de 1,5 caixas para o caso de temperatura ambiente de 16,5 °C e 10 caixas e o erro médio foi de 0,33 caixas. Sendo assim, a rede de regressão também foi considerada bem sucedida para classificação dos casos de treinamento.

Tabela 1: Resultados da rede de classificação para as médias das entradas de treinamento

Entradas					Resultado da rede			
t_{on}	t_{off}	t_r	T_{amb}	CX	0	10	20	30
[s]	[s]		[°C]	[cx]	cx	cx	cx	cx
239	829	0,29	16,5	0	94%	6%	0%	0%
252	988	0,25	16,5	10	1%	91%	8%	0%
281	1087	0,26	16,5	20	0%	0%	99%	1%
319	1212	0,26	16,5	30	0%	0%	2%	98%
246	755	0,32	20	0	99%	1%	0%	0%
257	822	0,31	20	10	11%	88%	0%	0%
288	859	0,33	20	20	0%	5%	95%	0%
329	1042	0,32	20	30	0%	0%	5%	95%
287	640	0,45	27	0	100%	0%	0%	0%
321	677	0,47	27	10	0%	90%	10%	0%
350	776	0,45	27	20	0%	1%	99%	0%
402	871	0,46	27	30	0%	0%	1%	99%
325	558	0,58	32	0	98%	2%	0%	0%
365	606	0,60	32	10	0%	99%	1%	0%
420	701	0,60	32	20	0%	0%	100%	0%
480	798	0,60	32	30	0%	0%	3%	97%

Tabela 2: Resultados da rede de regressão para as médias das entradas de treinamento

Entradas				CX	Resultado da rede	Erro
t_{on}	t_{off}	t_r	T_{amb}			
[s]	[s]		[°C]	[cx]	[cx]	[cx]
239	829	0,29	16,5	0	0,07	0,07
252	988	0,25	16,5	10	11,50	1,50
281	1087	0,26	16,5	20	20,27	0,27
319	1212	0,26	16,5	30	29,78	-0,22
246	755	0,32	20	0	0,01	0,01
257	822	0,31	20	10	10,33	0,33
288	859	0,33	20	20	20,81	0,81
329	1042	0,32	20	30	29,40	-0,60
287	640	0,45	27	0	0,00	0,00
321	677	0,47	27	10	10,35	0,35
350	776	0,45	27	20	20,52	0,52
402	871	0,46	27	30	29,85	-0,15
325	558	0,58	32	0	0,03	0,03
365	606	0,60	32	10	10,14	0,14
420	701	0,60	32	20	20,20	0,20
480	798	0,60	32	30	30,00	0,00

Avaliou-se valores de entrada interpolados entre as médias dos dados e extrapolado, ou seja, para carregamentos de 5, 15 e 25 caixas e 35 caixas.

Percebeu-se que, conforme esperado, nas situações de carregamento intermediário, a rede neural de classificação tendeu a priorizar um dos valores mais próximos, em alguns casos retornando maior probabilidade para valores imediatamente inferiores e, em outros, retornando valores imediatamente maiores do que o carregamento simulado. Já para as entradas extrapoladas de 35 caixas, valor superior a todos os valores de treinamento, nesses casos a rede retornou 99% ou 100% para 30 caixas, que foi o valor máximo de treinamento.

A rede de regressão foi capaz de aproximar os resultados dos valores interpolados para os carregamentos intermediários de 5, 15 e 25 caixas conforme era esperado, com erro médio de 1,2 caixas. O erro máximo de 2,9 caixas foi encontrado para o caso de 20°C e 5 caixas. Já para os valores extrapolados de 35 caixas, a rede apresentou um erro de 5 caixas por ser limitada a um resultado de 30 caixas devido à sua própria implementação matemática com o neurônio sigmoide. No entanto, esse resultado não é visto como um problema devido à configuração de 30 caixas já representar praticamente a capacidade máxima do refrigerador.

Os mesmos valores médios de treinamento foram fornecidos para a rede neural que realiza regressão no microcontrolador. A rede neural implementada no microcontrolador foi capaz de classificar os dados fornecidos com sucesso. Percebeu-se que a capacidade de processamento necessária é baixa e possível de ser realizada por um microcontrolador sem problemas, já que se obteve um tempo médio de resposta de 7 ms para simular a rede neural e retornar o seu resultado.

Conclusões

Constatou-se que a utilização de redes neurais para identificação de carregamento de produto em refrigeradores domésticos é possível de ser realizada, tanto para a rede neural utilizada para o problema de classificação discreta do carregamento entre 0, 10, 20 e 30 caixas quanto para o problema de regressão contínua, retornando de 0 a 30 caixas como resultado. Foi possível treinar ambas as redes reduzindo o erro de forma que 99% dos dados de validação fossem corretamente previstos.

Nos testes com as médias dos valores de treinamento, a rede neural utilizada para regressão apresentou erro médio de 0,33 caixas, já a rede de classificação classificou corretamente todas as entradas, com probabilidade de 88% no pior caso.

Um fator muito importante do trabalho desenvolvido foi a possibilidade de embarcar a metodologia proposta em um microcontrolador e transformá-lo em um produto de baixo custo. O desempenho do procedimento foi avaliado ao ser implementado no microcontrolador ATmega328 e apresentou um tempo de processamento para os cálculos da rede neural de 7 ms, que é suficiente para a operação, não sendo constatada necessidade de hardware mais potente para realizar os cálculos.

O trabalho desenvolvido resulta em uma possível alternativa para previsão do carregamento aplicado em

refrigeradores, sem necessidade de sensores de carga, a partir do treinamento com dados adquiridos em testes prévios no mesmo equipamento. Esse resultado pode contribuir para futuros desenvolvimentos de algoritmos de redução de consumo para sistemas de refrigeração que necessitem do carregamento como dado de entrada.

Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico Pesquisa (CNPq) pelo suporte financeiro.

Referências

- Bulinaria, J. (2009). Step by Step Guide to Implementing a Neural Network in C. Disponível em: <https://www.cs.bham.ac.uk/~jxb/INC/nn.html>. Acesso em 04 mar. 2020.
- Fedriga, Natália Sens; Ghisi, Eneir; Lamberts, Roberto. (2009). Usos finais de energia elétrica no setor residencial brasileiro. Encontro Nacional de Conforto no Ambiente Construído, v. 10, p. 367-376.
- França, E. F. (2015). Influência do Carregamento de Produto na Resposta Dinâmica de um Refrigerador Doméstico. Trabalho de Graduação – Departamento de Engenharia Mecânica, Universidade Federal de Minas Gerais, Belo Horizonte.
- IBGE. (2019). Pesquisa Nacional por Amostra de Domicílios Contínua – PNAD Contínua. Disponível em: <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2101707>. Acesso em 13/01/2021.
- ISO 8187:1991: Household refrigerating appliances - Refrigerator-freezers - Characteristics and tests methods.
- Murta, B. J. et al. (2015). Impact of product load and thermostat setting in the energy consumption of a household refrigerator. International Congress of Mechanical Engineering, 23, Rio de Janeiro.
- Sá, L. C. B. et al. (2019). Prediction of environment parameters inside a greenhouse using an LSTM model, 25° ABCM International Congress of Mechanical Engineering, Uberlândia, Minas Gerais, Brasil.
- Saidur, Rahman; Masjuki, Haji Hassan; Choudhury, I. A. (2002). Role of ambient temperature, door opening, thermostat setting position and their combined effect on refrigerator-freezer energy consumption. Energy Conversion and Management, v. 43, n. 6, p. 845-854.

Aviso de responsabilidade

Os autores são os únicos responsáveis pelo material incluído neste documento.