

Arquitetura computacional para controle bioclimático: Avaliação e seleção de dados para Redes Neurais

Muriel Figueredo Franco¹; Anderson Priebe Ferrugem², Antônio César Silveira³

¹*Centro de Desenvolvimento Tecnológico – Universidade Federal de Pelotas – mffranco@inf.ufpel.edu.br*

²*Centro de Desenvolvimento Tecnológico – Universidade Federal de Pelotas – ferrugem@inf.ufpel.edu.br*

³*Faculdade de Arquitetura e Urbanismo – Universidade Federal de Pelotas – acsbs@uol.com.br*

1. INTRODUÇÃO

A preocupação da sociedade com o meio ambiente vêm crescendo nas últimas décadas. Junto com esse crescimento a tecnologia evolui á passos largos, auxiliando nos processos de redução de danos ao meio ambiente e no desenvolvimento de equipamentos para auxiliar neste setor. Uma Arquitetura computacional bioclimática, tem como objetivo efetuar um controle predial inteligente de modo a aproveitar da melhor maneira possível seus recursos arquitetônicos e meios passivos de ventilação, desse modo, diminuindo o impacto das construções e suas utilizações pelo homem no meio ambiente.

Para implementação desse controle existe na Ciência da Computação uma área denominada Inteligência Artificial, na qual nos fornece estruturas e ferramentas para buscar um comportamento inteligente em um sistema computacional. Uma dessas técnicas fornecidas é chamada de Redes Neurais, que é um processador paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso [HAYKIN, 2000].

Um dos maiores desafios na utilização de redes neurais é sua sensibilidade aos conjuntos de dados de treinamento, porque, dados que não são representativos ou com poucos exemplos significativos prejudicam o treinamento da rede gerando resultados errôneos, não condizentes com a função de entrada que se deseja aproximar. Focando no problema da seleção de dados, torna-se necessário uma avaliação minuciosa dos dados de treinamento, de modo, que sejam observados quais dados climáticos e prediais podem ser utilizados para a rede neural alcançar um bom desempenho.

2. METODOLOGIA

Para a implementação de nosso controle foi modelada pelo Laboratório de Conforto e Eficiência Energética de Universidade Federal de Pelotas (LABCEE) utilizando o software Design Builder uma construção eficiente de 100m² contendo sala de estar e cozinha, dois dormitórios, banheiro, sala de serviço e jardim de inverno. O protótipo é mostrado na Fig. 1.



Figura 1: Modelo desenvolvido pelo LABCEE

O controle foi desenvolvido com ênfase na Sala de estar (com jardim de inverno anexado) e cozinha, visto que juntas possuem a maior área e maior número de conexões com o ambiente externo (Fig. 2).

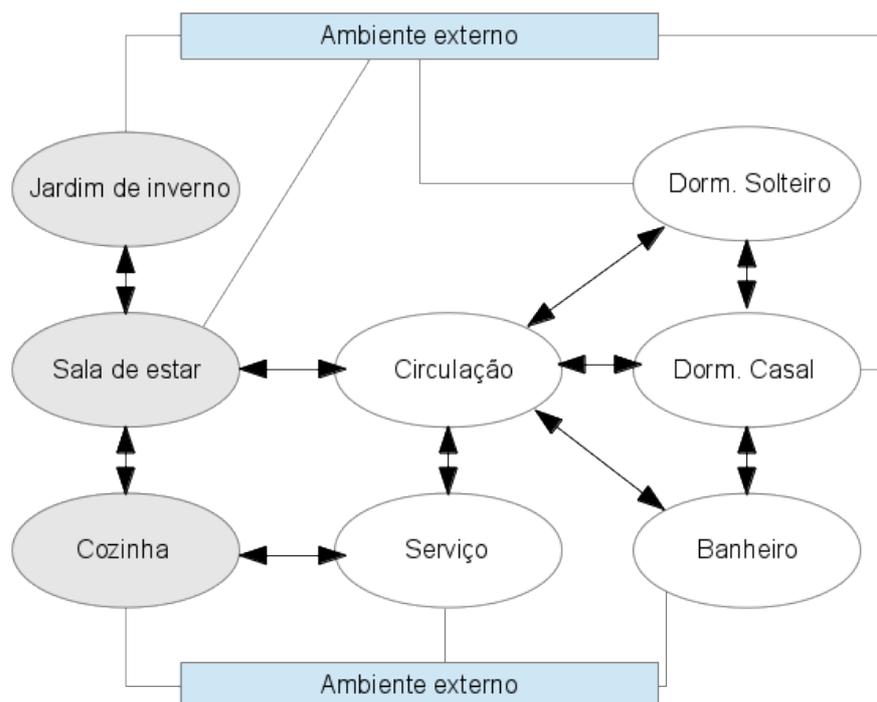


Figura 2: Grafo com as conexões entre os ambientes

Foi utilizado o software MATLAB para a implementação de nosso algoritmo, onde através da utilização de um software chamado BCVTB é possível realizar um link durante a simulação entre o algoritmo implementado no MATLAB e a construção modelada no Design Builder [FRANCO, 2012]. Esse link é representado na Fig. 3.

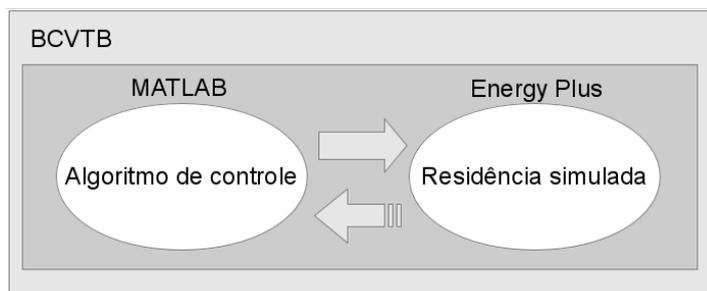


Figura 3: Conexão criada utilizando BCVTB

Escolhemos o modelo de rede neural *multilayer perceptron* (perceptron multicamadas) com algoritmo de aprendizado *backpropagation* por ser um modelo bastante conhecido na literatura e adequado a abordagem adotada [DEMUTH e BEALE, 1993]. O *multilayer perceptron*, de acordo com o teorema de aproximação universal [HAYKIN, 2000], se comporta como um aproximador de funções, o que o torna adequado para construção do controle, visto que, dado um conjunto de entradas ambientais e de estados das aberturas, se deseja mapear um comportamento das aberturas próximo ao ideal em relação ao conforto climático interno. Tendo em vista este objetivo, nossa rede neural atua controlando a abertura e o fechamento das janelas na região definida, com o objetivo de manter o ambiente agradável ao ser humano utilizando apenas a ventilação natural.

Para avaliar a eficiência de nosso controle utilizamos uma variável chamada de Voto Médio Estimado de Fanger (PMV), um índice de conforto térmico que traduz a sensibilidade humana ao frio e ao calor em um valor numérico, podendo variar entre o intervalo de -3 a 3. Quanto mais próximo de 0, mais agradável está para o ser humano. Assim, após o controle inteligente tomar suas decisões podemos avaliar se ele gerou resultados realmente satisfatórios.

2.1. TREINAMENTO DA REDE NEURAL

Após diversas tentativas e análises de resultados adotamos como topologia da rede neural 3 camadas com função de transferência sigmoideal logarítmica, sendo: uma camada de entrada com 9 neurônios, uma camada oculta com 2 neurônios e uma camada de saída com apenas 1 neurônio.

A seleção de dados para o treinamento da rede neural é uma tarefa que requer grande atenção, pois o sucesso do controle depende quase que exclusivamente desse processo. Os dados foram avaliados por dois grupos de trabalho: especialistas em Eficiência energética e especialistas em Inteligência artificial. Desse modo foi possível a análise de quais dados climáticos podem ser importantes para a criação do conjunto de treinamento.

Selecionamos como base de entrada para a rede neural os dados climáticos: temperatura externa, temperatura interna, velocidade e direção do vento, umidade relativa do ar, direção e radiação solar. Como base de treinamento para a saída foi utilizado os estados das janelas variando entre 0 (fechado) e 1 (aberto). Esses dados foram extraídos do resultado de um controle utilizando um conjunto de regras fixas para controlar as janelas. A

Tab.1 contém os alguns critérios utilizados para cada seleção de dados, onde cada linha representa uma rede neural treinada com dados diferentes.

Conjunto de dados para treinamento da rede neural	Desempenho
Dados que resultaram em um PMV dentro da faixa de conforto	56%
Dados aleatórios	38%
Dados contendo valores extremos das variáveis climáticas	42%
Dados contendo valores extremos e valores intermediários	46%

Tabela 1: Conjunto de dados utilizados no treinamento da rede neural e seu desempenho para a simulação do mês de Janeiro

Após os treinamentos apresentados na Tab.1 foi observado que algumas variáveis climáticas estavam induzindo a rede neural ao erro e também causando alguns vícios indesejáveis, como exemplo, a radiação solar se fixa em 0 durante a noite prejudicando assim o aprendizado da rede neural. Com isso após uma avaliação climática foi decidido a redução para apenas quatro dados climáticos como base de entrada: temperatura externa e interna, velocidade e direção o vento. Esses dados foram escolhidos por estarem diretamente relacionados com a tomada de decisão sobre abrir ou fechar janelas.

3. RESULTADOS E CONCLUSÕES

Após a redução das variáveis climáticas, observamos ainda que os primeiros dias simulados continham valores discrepantes devido ao erro embutido nos softwares de simulação. Com isso, retiramos da base de avaliação os primeiros cinco dias (120 horas), mantendo o conjunto de entrada com os dados climáticos reduzidos e utilizando para o treinamento dados com o PMV na faixa entre -0.2 e +0.2. Obtivemos como resultado um desempenho de 68% (relacionado ao percentual de horas totais em conforto térmico), superando assim todos os conjuntos de dados anteriores apenas reavaliando os dados de treinamento.

As redes neurais apresentam limitações devido ao fato de serem sensíveis aos seus dados de treinamento, acertando suas decisões quando essa está inerente em seu conhecimento e falhando em situações não presentes em seu conjunto de treinamento. Embora tenha sido obtido um grande potencial de generalização da rede neural, torna-se necessário um novo processo de avaliação dos dados de treinamento e a implementação de novas técnicas para extração desses dados.

4. REFERÊNCIAS BIBLIOGRÁFICAS

- [0] HAYKIN, S. - **Redes Neurais: princípios e práticas**. Bookman, 2000. 2e.
- [1] FRANCO, M. - Automação e controle de simulações energéticas utilizando o BCVTB. In: **21º CONGRESSO DE INICIAÇÃO CIENTÍFICA UFPEL**, Pelotas, 2012, Anais XXI CIC, Universidade Feradel de Pelotas.
- [2] DEMUTH, H. e BEALE, M. - **Neural Network Toolbox**. Mathworks, 1993.