

XVIII

CIC

XI ENPOS
I MOSTRA CIENTÍFICA



Evoluir sem extinguir:
por uma ciência do devir



APLICAÇÕES DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL PARA GERENCIAMENTO ENERGÉTICO E CONFORTO TÉRMICO EM EDIFICAÇÕES

REINKE, Davi Decker¹; DIAS, William Régis Drawanz¹; MOURA, Bruno da Silveira¹; FERRUGEM, Anderson Priebe¹.

Grupo de Aplicações em Inteligência Artificial (GAIA)

¹Departamento de Informática – Universidade Federal de Pelotas

Campus Universitário – Caixa Postal 354 – CEP 96010-900 - dreinke.ifm@ufpel.edu.br

1. INTRODUÇÃO

No Brasil, mais de 40% da energia elétrica é consumida só no uso das edificações (Lamberts *et al.*, 2001). A criação de novas ferramentas capazes de diminuir gastos desnecessários de energia elétrica, através do gerenciamento inteligente dos recursos disponíveis, sem causar desconforto ao usuário, poderia colaborar na redução deste consumo.

O uso racional da energia elétrica em edificações inicia pelo projeto arquitetônico, que orientado por princípios bioclimáticos, pode reduzir o uso de condicionamento artificial ou, até mesmo, torná-lo desnecessário. Igualmente importante é a especificação de equipamentos eficientes (eletrodomésticos com selo do Programa de Combate ao Desperdício de Energia Elétrica do Governo Federal, por exemplo) e verificação se estes podem ser substituídos, ou ter seu uso reduzido, por tecnologias alternativas de menor consumo energético (lâmpadas fluorescentes, aquecedor de água a gás ao invés de chuveiros, dentre outros). Porém, em grande parte o consumo energético depende que o usuário faça um uso correto dos recursos disponibilizados.

Pfafferott *et al.* (2007) verificou uma grande influência dos usuários no balanço de energia em edifícios de escritórios de baixo consumo energético com associação de condicionamento natural e artificial, devido ao manuseio de janelas e dispositivos de sombreamento. Todavia, operar os dispositivos no momento correto e oportuno, e que, algumas vezes, afetam mais o desempenho térmico e energético da edificação do que o próprio conforto pessoal naquele momento, exigem conhecimento e ampla experiência do usuário. Parte da solução pode estar na automação predial.

Através de um sistema automatizado, seria possível controlar de forma mais eficiente aberturas, dispositivos de sombreamento e, caso necessário, condicionamento artificial. Várias técnicas computacionais inteligentes foram propostas e experimentadas, tais como Redes Neurais, Lógica Difusa, Modelos Escondidos de Markov, Classificador Bayes, entre outros (Begg & Hassan, 2006). Cada uma dessas técnicas possui vantagens e desvantagens quando aplicadas ao controle de uma residência. Entre essas técnicas, a de Redes Neurais Artificiais é relativamente simples de ser aplicada em ambientes reais. Suas características de

adaptabilidade a esse problema, a torna mais adequada ao controle e automação de dispositivos diversos encontrados em um ambiente residencial inteligente. Apesar de possuir limitações em relação a arquitetura ótima e problemas de mínimos locais, ela tem sido utilizada com êxito em muitos problemas de controle de residências inteligentes (Begg & Hassan, 2006).

Uma Rede Neural Artificial (RNA) é composta por várias unidades de processamento. Essas unidades são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma RNA vem das interações entre as unidades de processamento da rede.

2. METODOLOGIA

Uma Rede Neural Artificial é uma técnica inspirada em neurônios biológicos (Jain, 1996) e que pode adquirir conhecimento através da experiência. Ela é composta por unidades simples de processamento interligadas através de uma rede conectando saídas a entradas de neurônios específicos segundo uma topologia definida. Uma das vantagens da Rede Neural Artificial é sua capacidade de aprender por amostragem, desta forma não é necessário conhecer a equação que representa o comportamento do sistema onde existem muitas variáveis e suas interrelações não são conhecidas.

Este trabalho utiliza redes de Perceptrons de Múltiplas Camadas (*Multilayer Perceptrons - MLP*), pois este tipo de RNA é um aproximador universal, capaz de aprender mapeamentos arbitrariamente complexos.

A MLP é uma rede com uma camada de entrada que possui um neurônio para cada sinal de entrada, camadas ocultas de neurônios e uma camada de saída que, assim como a camada de entrada, possui um neurônio para cada sinal de saída (Figura 2).

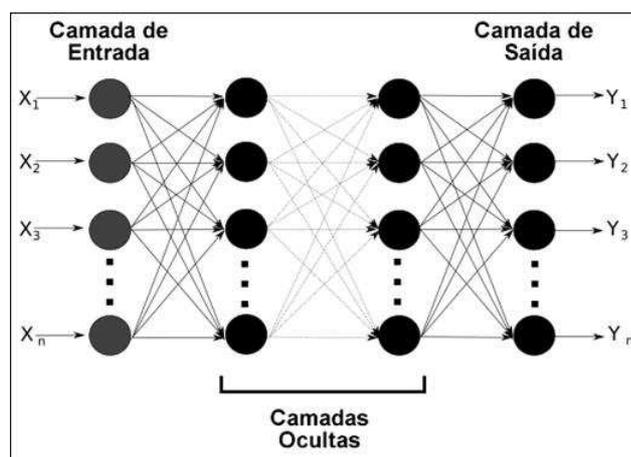


Figura 2 – Rede Neural MLP.

Para que a rede MLP seja treinada é necessário um conjunto considerável de exemplos que, neste caso, contém valores referentes a temperatura interna e externa da edificação, umidade, luminosidade, abertura das janelas e portas, entre outros. Parte dessas variáveis são passadas como entrada para a RNA e outra parte como alvo a ser alcançado. A rede passa a ser treinada e, durante

essa fase, regula os pesos de cada uma das entradas até atingir um nível aceitável de erro.

Algumas ferramentas, como é o caso do *Energy Plus* versão 1.31a da GARD Analytics (GARD ANALYTICS, 2009) e sua interface através do *Design Builder* versão 2.0.4 (DesignBuilder Software Ltd, 2009), permitem o acionamento de diversos dispositivos (janelas, cortinas, etc.) e a simulação desses modelos. O auxílio destas ferramentas permite que os exemplos necessários sejam gerados e simulados.

O modelo de edificação, gerado através do *Design Builder*, ao ser simulado pelo *Energy Plus*, resulta em um exemplo de entrada. Para otimizar o processo de criação de exemplos, foi desenvolvida uma ferramenta capaz de gerar, a partir de um modelo criado com o *Design Builder*, uma série de variações que representam as diversas posições das aberturas da edificação. O arquivo de saída usado como exemplo na rede contém o Voto Médio Previsto (*Predicted Mean Vote - PMV*) (Fanger, 1970), adotado como parâmetro para análise das condições internas. Esta variável expressa maior conforto térmico à medida que se aproxima de zero, sendo quente para valores positivos e frio para valores negativos.

3. RESULTADOS E DISCUSSÃO

Foram geradas setecentos e vinte e nove tabelas contendo dados para amostragem. Cada tabela corresponde a uma variação das condições físicas das aberturas da edificação, sendo esta condição representada por seis valores que podem variar de zero a um. Nesse caso, estamos utilizando apenas três variações diferentes desse valor, sendo elas: 0, correspondendo a janela totalmente fechada; 0,5, correspondendo a janela meio aberta; e 1, correspondendo a janela totalmente aberta. Além disso, cada tabela contém os valores de PMV para cada hora do mês de janeiro.

A partir dos resultados obtidos, foram calculadas as médias para quatro períodos do dia, bem como selecionadas as médias que se enquadram em uma faixa aceitável de conforto térmico. Nas Figuras 3, 4 e 5 podem ser vistos gráficos que demonstram as variações de PMV por dia, para quatro diferentes faixas de horários.

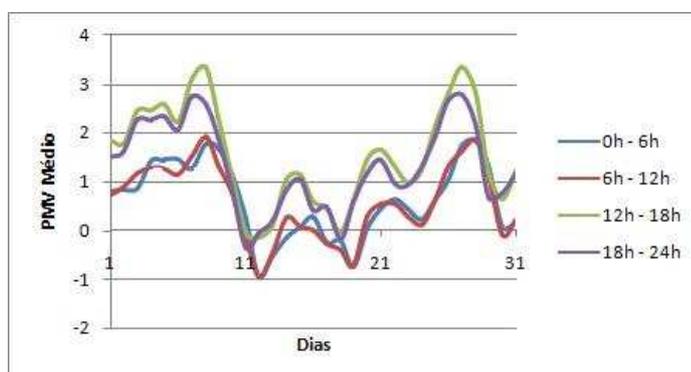


Figura 3 – Relação PMV x Dia para janelas fechadas.

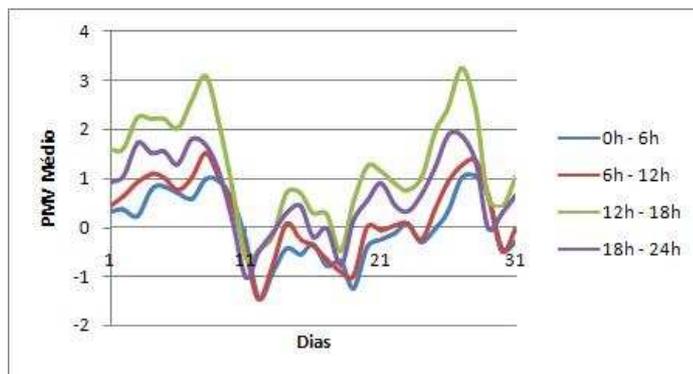


Figura 4 – Relação PMV x Dia para janelas meio abertas.

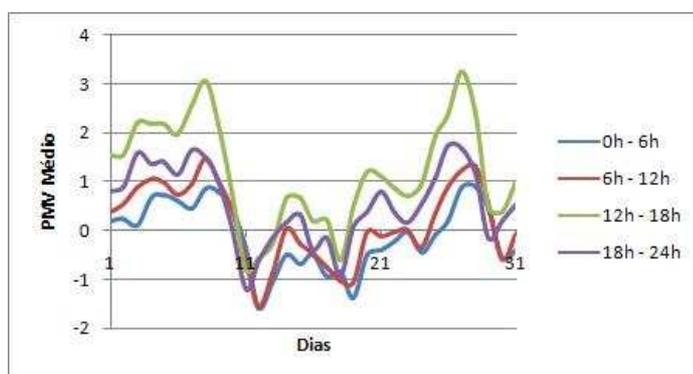


Figura 5 – Relação PMV x Dia para janelas abertas.

Estes resultados compreendem uma etapa importante do desenvolvimento desse trabalho, pois acumulam os dados necessários para o treinamento da RNA. Porém, este trabalho apresenta apenas a geração dos exemplos para a rede.

A RNA está sendo desenvolvida usando a ferramenta MatLab R2009a versão 7.8.0.347 da The MathWorks (THE MATHWORKS, 2001). A entrada da rede MLP possuirá um neurônio para cada dado referente as condições climáticas e de luminosidade, no interior e exterior da edificação. A saída possuirá seis neurônios, um para cada abertura da edificação. O treinamento da rede será feito com os exemplos obtidos até então.

4. CONCLUSÕES

Esse trabalho propõe a aplicação de técnicas de inteligência artificial para gerenciamento energético e conforto térmico em edificações, contribuindo com a economia de energia elétrica em edificações, bem como a simplificação da manipulação das técnicas de controle, proporcionando maior conforto térmico.

Como trabalho futuro, será desenvolvida a rede neural de forma completa, utilizando processo de desenvolvimento semelhante ao descrito neste trabalho.

5. REFERÊNCIAS BIBLIOGRÁFICAS

DESIGN BUILDER. DesignBuilder v.2.0.4.002, DesignBuilder Software Ltd., Disponível em <www.designbuilder.co.uk>, acesso em 13 ago.
Begg R.; Hassan R. **Artificial Neural Networks in Smart Homes**, Designing Smart Homes: The Role of Artificial Intelligence, Springer-Verlag, 2006.

ENERGYPLUS. **Input Output Reference**, The Encyclopedic Reference to EnergyPlus Input and Output, 2008.

FANGER, P.O. **Thermal Comfort**, McGraw Hill Book Company, 1970.

JAIN, A. K.; MAO, J. Artificial Neural Networks: A Tutorial. **IEEE Xplore**, IEEE Computer Society, 1996.

LAMBERTS, R.; DUTRA, L.; PEREIRA, F.O.R. **Eficiência Energética na Arquitetura**, ProLivros, 2001.

MATSUMOTO, É.Y. **MATLAB 6 - Fundamentos de programação**, Érica. 2001.

PFATTEROTT, J. U.; HERKEL, S.; KALZ, D. E. e ZEUSCHNER, A. Comparison of low-energy office buildings in summer using different thermal comfort criteria. **Energy and Buildings**, 2007.