



EIXO TEMÁTICO:

- | | | |
|---|---|--|
| <input checked="" type="checkbox"/> Ambiente e Sustentabilidade | <input type="checkbox"/> Crítica, Documentação e Reflexão | <input type="checkbox"/> Espaço Público e Cidadania |
| <input type="checkbox"/> Habitação e Direito à Cidade | <input type="checkbox"/> Infraestrutura e Mobilidade | <input type="checkbox"/> Novos processos e novas tecnologias |
| <input type="checkbox"/> Patrimônio, Cultura e Identidade | | |

Método para a avaliação da contribuição da iluminação natural na redução do consumo energético em edifícios não-residenciais utilizando redes neurais artificiais

Method for evaluating daylighting contribution for energy consumption savings in non-residential buildings using artificial neural networks

Método para evaluar la contribución de luz natural en la reducción del consumo de energía en edificios no residenciales mediante redes neuronales artificiales

FONSECA, Raphaela Walger(1);

PEREIRA, Fernando O. Ruttkay (2)

(1)Doutoranda, Universidade Federal de Santa Catarina, UFSC – PPGEC, Florianópolis, SC, Brasil; email: raphawf@gmail.com

(2)Professor Doutor, Universidade Federal de Santa Catarina, UFSC – PosARQ/PPGEC, Florianópolis, SC, Brasil; email: feco@arq.ufsc.br

Método para a avaliação da contribuição da iluminação natural na redução do consumo energético em edifícios não-residenciais utilizando redes neurais artificiais

Method for evaluating daylighting contribution for energy consumption savings in non-residential buildings using artificial neural networks

Método para evaluar la contribución de luz natural en la reducción del consumo de energía en edificios no residenciales mediante redes neuronales artificiales

RESUMO

Métodos simplificados de avaliação de iluminação natural são importantes ferramentas idealizadas para serem utilizadas em especial nas fases iniciais de projeto. Apesar de existir uma grande quantidade de ferramentas baseadas em métodos simplificados para a avaliação de diferentes soluções de projeto que contemplem a iluminação natural, existe um número reduzido delas que ofereçam a possibilidade de avaliação do impacto de sua aplicação no consumo energético considerando as implicações no padrão de uso do sistema de iluminação artificial e no condicionamento de ar. As técnicas de Regressão Não Linear Multivariada através de Redes Neurais Artificiais tem sido utilizadas com boa resposta para modelagens do desempenho energético em edificações. Entretanto, necessitam de um universo de exemplos previamente apresentados permitindo que possa generalizar soluções para problemas semelhantes. Neste sentido, o objetivo deste trabalho é avaliar conjuntos de amostragens que possam ser utilizadas para modelar o desempenho energético de edifícios considerando a iluminação natural. Como resultados obtiveram-se erros aceitáveis para as três amostras testadas, indicando-se um balanço entre tempo de processamento e erro admissível para futuras aplicações do método.

PALAVRAS-CHAVE: iluminação natural, consumo energético, hipercubo latino, redes neurais artificiais

ABSTRACT

Simplified methods for daylighting evaluation are important tools developed to be used in particular in the early stages of design process. Despite of the big amount of tools based on simplified methods for assessment daylighting, there is a small number of them that offer the possibility of assessing the impact of its application in energy consumption considering the implications on the lighting density power use and air conditioning consumption. Artificial Neural Networks have been used with good response for modeling energy performance in buildings. However, these techniques require a universe of examples previously presented allowing to generalize solutions to similar problems. In this sense, the objective of this study is to evaluate sets of samples that can be used to model buildings energy performance considering daylighting. Since acceptable errors for the three samples tested were yielded, these research indicate a balance between processing time and error goal as decision argument for future applications of the method.

KEY-WORDS: daylighting, energy consumption, Latin hypercube sampling, artificial neural network

RESUMEN

Los métodos simplificados para evaluar la iluminación natural se constituyen en importantes herramientas utilizadas, principalmente, en las fases iniciales de proyecto. Aunque existen múltiples herramientas basadas en estos métodos para evaluar la iluminación natural a partir de diferentes soluciones de proyecto, son pocas las herramientas que permiten evaluar el impacto de su aplicación, en dichas fases de proyecto, y el posterior consumo energético, considerando los patrones de uso de la iluminación artificial y de los sistemas de aire acondicionado. Las técnicas de Regresiones Lineales Multivariadas, a través de redes Neuronales, han sido utilizadas y han obtenido una buena respuesta en los modelos de desempeño energéticos de las edificaciones. Sin embargo, esos modelos necesitan un



universo de exemplos presentados con antelación y así permitir la generalización de las soluciones para problemas que sean semejantes. El objetivo de este trabajo es evaluar los conjuntos de muestras que puedan ser utilizadas para modelar el desempeño energético de edificios que usan la iluminación natural. Los resultados obtenidos presentaron errores aceptables para las tres muestras analizadas indicando un equilibrio entre el tiempo de procesamiento y el error admisible, factores que deberán ser considerados en las futuras aplicaciones del método.

PALABRAS-CLAVE: luz natural, el consumo de energía, Latin Hypercube, redes neuronales artificiales

1 INTRODUÇÃO

Nos últimos anos, quando se começou a falar mais sistematicamente sobre racionalização do uso da energia elétrica nos edifícios, o aspecto da integração entre luz natural e artificial passou a assumir importância cada vez maior. A preferência pela luz natural como fonte de luz em edifícios deve-se a uma série de fatores relacionados com o cumprimento das necessidades biológicas humanas.

Métodos simplificados de avaliação de iluminação natural são importantes ferramentas idealizadas para serem utilizadas em especial nas fases iniciais de projeto. Estas ferramentas são idealizadas para dar respostas rápidas sem necessitar detalhamento de informações. Normalmente são utilizadas para comparar o desempenho de diferentes soluções de projeto. Além disso, estas ferramentas podem ser utilizadas também para avaliações simplificadas de projetos já concluídos, com o objetivo de classificar o desempenho do projeto, por exemplo.

Apesar de existir uma grande quantidade de ferramentas baseadas em métodos simplificados para a avaliação de diferentes soluções de projeto que contemplem a iluminação natural, existe um número reduzido delas que ofereçam a possibilidade da avaliação do impacto de sua aplicação no consumo energético considerando as implicações no padrão de uso do sistema de iluminação artificial e no condicionamento de ar.

Na área de eficiência energética em edificações, muitas pesquisas relacionadas à elaboração de Códigos e Normas fazem uso do modelo de Regressão Linear Multivariada em suas análises, como exemplo no cenário nacional, o RTQ-C. Entretanto o uso de Regressão Não Linear Multivariada para a aproximação de funções ainda não é muito difundido. As técnicas de Regressão Não Linear Multivariada através de Redes Neurais Artificiais tem sido utilizadas com boa resposta para modelagens em várias áreas de pesquisa. A motivação para a utilização desta técnica é a sua boa resposta para modelos não lineares. Para tornar mais efetivo o uso das redes neurais artificiais, depois de treinada a rede pode ser convertida em uma ferramenta em formato de planilha, facilitando sua aplicação para avaliação de novos casos.

No sentido de avançar neste tipo de avaliação o objetivo deste trabalho é avaliar conjuntos de amostragens que possam ser utilizadas para modelar o desempenho energético de edifícios considerando a iluminação natural através do uso de redes neurais artificiais.

2 FUNDAMENTAÇÃO TEÓRICA

REDES NEURAS ARTIFICIAIS

As redes neurais artificiais (ANNs) são técnicas computacionais que utilizam modelo matemático inspirado na estrutura biológica do cérebro humano fazendo uma analogia com o

funcionamento do neurônio e suas conexões. Estas técnicas buscam reproduzir o comportamento e a dinâmica do cérebro adquirindo conhecimento através da experiência. As ANNs têm por objetivo fornecer subsídios para que a ferramenta computacional consiga, baseada em um conjunto de simulações conhecidas, estender tais informações para uma determinada situação proposta (COSTA, 2001).

Um dos tipos de redes mais difundidos no momento são as perceptron multicamadas. Consistem em um conjunto de unidades sensoriais, formando uma camada de entrada, uma ou mais camadas intermediárias de unidades ocultas e uma camada de saída. A propagação dos sinais de entrada acontece de camada a camada na direção positiva (da entrada para a saída) (BOCANEGRA, 2002).

A estrutura básica de uma ANN é o neurônio. Haykin (2001) define o neurônio artificial como uma unidade de processamento matematicamente simples, pois recebe uma ou mais entradas, que por sua vez têm um peso associado, e as transforma em saídas. O conhecimento da rede é representado pelos pesos, que determinam a importância que cada entrada possui.

A forma como os neurônios estão estruturados na rede neural está fortemente relacionada com o algoritmo de aprendizagem¹ utilizado para treinar a rede (HAYKIN, 2001). Os algoritmos de aprendizagem abordados neste trabalho serão Gradiente Descendente, Levenberg Maquardt e Bayesian Regularization.

O aprendizado da rede é o processo pelo qual ocorre o ajuste dos pesos sinápticos, uma rede com pesos sinápticos adequados pode representar praticamente qualquer função. Para tal, inicia-se o processo adotando-se pesos arbitrários e iterativamente aplicando um algoritmo de aprendizagem a rede pode chegar no desempenho desejado.

O algoritmo da retropropagação consiste em dois passos através de diferentes camadas da ANN, a propagação (passo para frente) e a retropropagação (passo para trás). Haykin (2001) descreve: na propagação, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais da rede e seu efeito se propaga através da rede camada por camada, produzindo um conjunto de saídas como resposta real da rede. Neste passo, os pesos sinápticos da ANN são todos fixos. Já durante a retropropagação, ocorre o ajuste dos pesos de acordo com a regra da correção do erro, calculando-se o erro quadrático médio das saídas. Neste caso, o algoritmo também é conhecido como Gradiente Descendente que procura aproximar a curva do erro em um ponto por uma reta. O algoritmo aqui discutido apresenta críticas quanto ao tempo de treinamento. Visando reduzir este tempo, uma série de propostas foram desenvolvidas, entre elas os métodos de Newton e Levenberg-Marquadt. Este último utiliza a aproximação do erro ora por reta e ora por curva, conforme necessário. O algoritmo Bayesian regularization suaviza a resposta da rede, pois não só otimiza o erro, como busca manter os valores dos pesos pequenos aumentando a capacidade de generalização da rede.

AMOSTRAGEM POR HIPERCUBO LATINO

As técnicas de amostragem aparecem como uma solução para estudos onde o número de simulações paramétricas se tornaria inviável. Dentre as técnicas de amostragem, uma bastante difundida é o Método de Monte Carlo. Outra técnica de amostragem que possibilita uma redução significativa no número de modelos a serem simulados é a amostragem por

¹ Algoritmo de aprendizagem: pode ser definido como um conjunto preestabelecido de regras bem definidas para a solução de um problema de aprendizagem (HAYKIN, 2001).

Hipercubo Latino (AHL). Este método caracteriza-se pela divisão da faixa de incertezas em sub-regiões e em cada uma destas regiões são realizados sorteios (a amostragem) forçando que o número de sorteios esteja na faixa correspondente a ser analisada (RISSO, RISSO e SCHIOZER, 2010).

O Hipercubo Latino é uma aplicação do método de Monte Carlo. A diferença básica entre os métodos consiste na maneira como os ensaios são realizados. No método de Monte Carlo, são realizados sorteios aleatórios baseados na distribuição das probabilidades, enquanto que no Hipercubo Latino, apesar dos sorteios também serem aleatórios, estes se dão dentro as faixas previamente definidas (MASCHIO, CARVALHO e SCHIOZER, 2009).

A aplicação do AHL irá determinar a dimensão do experimento. De acordo com Barlett, Kotrlik, Higgins (2001) para cada tipo de variável, discreta ou contínua, um tamanho diferente de amostra é recomendado, no caso de estudos abordando análise de regressão multivariada. Para variáveis contínuas, a amostra deve ser em torno de dez vezes o número de parâmetros em questão. Já para variáveis discretas esta pode ser cinco vezes o número de parâmetros. Amostras menores correm o risco de *overfitng*, ou seja, os resultados obtidos podem ser muito específicos da amostra em questão, diminuindo o caráter generalista da amostragem.

Outros autores utilizaram o Hipercubo Latino como técnica para amostragem de modelos na realização do planejamento estatístico combinado com técnicas de redes neurais artificiais (ZERPA *et al.*, 2005, MELO, 2012). Com isso verifica-se a técnica com grande potencial de ser adotada também quando o foco trata de iluminação natural, entretanto deve-se selecionar cuidadosamente o número de amostras que possam adequadamente representar o universo a ser modelado.

3 MÉTODO

O método aplicado visando definir uma amostra representativa do conjunto de combinações dos parâmetros chave para iluminação natural pra a proposição de um metamodelo baseado em redes neurais artificiais seguiu as seguintes etapas:

- 1- Definição de variáveis chaves para a iluminação natural relacionadas ao consumo energético da edificação;
- 2- Amostragem por hipercubo latino;
- 3- Parametrização dos modelos;
- 4- Simulação integrada de iluminação natural e energia;
- 5- Teste de normalidade das amostras;
- 6- Modelagem usando redes neurais artificiais.

DEFINIÇÃO DAS VARIÁVEIS CHAVES DE ILUMINAÇÃO NATURAL

Para a definição das variáveis chaves de iluminação natural com impacto no consumo energético, foram elencadas variáveis do **contexto da edificação**, tais como localidade e obstrução do entorno, variáveis da **descrição do edifício**, como geometria e refletância das superfícies e variáveis do **desempenho do edifício**, utilizadas para avaliá-lo, tais como Autonomia da Luz Natural Espacial e consumo em iluminação. A fim de avaliar o duplo impacto da iluminação natural no consumo energético, através da redução do consumo com iluminação

artificial e do impacto no sistema de condicionamento de ar pela redução do calor gerado pelas lâmpadas foram considerados a também alguns parâmetros relacionados ao desempenho térmico da edificação. Estes parâmetros foram enquadrados na categoria de **desempenho do edifício**.

Para cada parâmetro foram selecionados valores de forma a cobrir a maior variedade de possibilidades de ambientes. Visto que as amostragens foram geradas com o objetivo de alimentar metamodelos, priorizou-se selecionar valores que abarcassem casos extremos. Este partido é indicado para a modelagem de redes neurais artificiais devido ao seu grande poder de generalização, mas limitação em extrapolação.

AMOSTRAGEM POR HIPERCUBO LATINO

A amostragem por hipercubo latino foi realizada no programa MatLab, utilizando como base a função $lhsdesign(n,p)$. A função retorna uma matriz n por p , contendo uma amostra por hipercubo latino de n valores de cada um dos parâmetros (p). Para cada coluna da matriz, os n valores são distribuídos aleatoriamente para cada intervalo $(0,1/n)$, $(1/n,2/n)$,..., $(1-1/n,1)$, e são permutados aleatoriamente (MATLAB, 2014).

Para uma estimativa inicial do número de casos a serem amostrados, utilizou-se dois balizamentos. Primeiramente foi realizado um teste de normalidade com os dados de um estudo semelhante, de Fonseca, Didoné e Pereira (2013) em que foram comparados os métodos de regressão linear multivariada e redes neurais artificiais para a modelagem do consumo energético considerando a iluminação natural baseado em simulação integrada. Os resultados da simulação integrada deste estudo foram submetidos ao teste de normalidade Kolmogorov-Smirnov. Apesar do conjunto de dados não abranger todas as variáveis que foram consideradas, julgou-se válido por tratar-se de um conjunto semelhante e que objetivava modelar o mesmo fenômeno. Vale salientar que o teste foi feito utilizando-se apenas o valor do consumo total da edificação, tratava-se de um conjunto de 216 casos paramétricos e as redes neurais artificiais apresentaram erro quadrático médio abaixo de $0,05\text{kWh/m}^2/\text{ano}$. Como este teste resultou em descarte da hipótese de normalidade optou-se pela realização de testes com diferentes números de amostra amostras.

Para a definição destes diferentes números de amostras baseou-se no estudo de Melo (2012) que utilizou redes neurais artificiais para modelar o consumo energético de edificações baseadas em dados simulados no programa EnergyPlus. Neste estudo também paramétrico, um conjunto de 4.572.288 casos foram amostrados em 200 casos também utilizando a técnica de hipercubo latino.

Propuseram-se então amostragens de 300, 200 e 100 casos para o conjunto de 5.971.968 casos. Vale salientar que este estudo contempla parâmetros de desempenho de iluminação natural e energia, os estudos anteriores foram realizados apenas considerado parâmetros de desempenho de energia, logo caso a maior amostra ainda não resultasse em erro aceitável maiores amostras seriam testadas.

PARAMATRIZAÇÃO DOS MODELOS

Como resultado das amostragens o programa Matlab gera planilhas com os parâmetros de cada caso amostrado, utilizadas como dado de entrada para o plugin Grasshopper (RUTTEN, 2011), plugin do programa Rhinoceros de modelagem tridimensional (MCNEEL, 2010), que

permite a geração de modelos paramétricos. Para tal, toda a modelagem é pré-preparada gerando um algoritmo de parametrização.

SIMULAÇÃO INTEGRADA DE ILUMINAÇÃO NATURAL E ENERGIA

Os desempenhos luminoso e térmico da edificação são simulados utilizando-se o plugin DIVA (JAKUBIEC E REINHART, 2011), também no programa Rhinoceros. O DIVA integra as simulações anuais de disponibilidade de luz natural do programa de simulação Daysim, que por sua vez utiliza o Radiance para a modelagem do fenômeno da iluminação natural (REINHART, 2010) com simulações térmicas do programa EnergyPlus.

Para tal, após a simulação anual de iluminação natural o Daysim gera, como dado de saída, além dos valores de medidas de iluminação natural, uma planilha de dados (*.intgain.csv) com o percentual da potência instalada acionado para cada ponto de análise durante todas as horas de ocupação, em função do aproveitamento da iluminação natural. Este arquivo é utilizado como dado de entrada para o EnergyPlus, como schedule de uso do sistema de iluminação artificial. Para este estudo foi utilizado um controle dimerizável contínuo baseado em uma iluminância alvo de 300 lux.

Como dados de saída da simulação foram solicitadas as seguintes medidas de iluminação natural:

- 1) FLD espacial igual ou maior a 1,62%, referente ao atendimento de uma iluminância mínima de 300 lux, para a cidade de Florianópolis, em 50% do tempo do período de ocupação dos ambientes.
- 2) FLD espacial igual ou maior a 1,10%, referente ao atendimento de uma iluminância mínima de 300 lux, para a cidade de Florianópolis, em 30% do tempo do período de ocupação dos ambientes;
- 3) Iluminâncias Úteis Espacial -sUDI_{50%} (IES LM-83-12, 2012), refere-se a porcentagem de área que as iluminâncias estão entre 100 e 2000 lux, por um determinado período de tempo, neste caso 50% das horas ao longo do ano;
- 4) Iluminâncias Úteis Espacial -sUDI_{30%} (IES LM-83-12, 2012), a mesma medida do item anterior, mas atendidas em apenas 30% das horas ao longo do ano;
- 5) Autonomia Espacial da Luz Natural- sDA_{300, 50%} (IES LM-83-12, 2012), refere-se a porcentagem de área que excede um valor mínimo de iluminância, no caso 300 lux, por um determinado período de tempo, neste caso 50% das horas ao longo do ano;
- 6) Autonomia Espacial da Luz Natural- sDA_{300, 30%} (IES LM-83-12, 2012), a mesma medida do item anterior, mas atendidas em apenas 30% das horas ao longo do ano;

Quanto à energia foram solicitados o consumo energético com aquecimento, resfriamento, iluminação, equipamentos, e total.

TESTE DE NORMALIDADE DAS AMOSTRAS

Para os testes de normalidade das três amostragens foi realizado o teste Kolmogorov-smirnov aplicado aos valores reais e transformados em escala logarítma. Adicionalmente, foram gerados histogramas de frequência de ocorrência para todos os parâmetros de saída das simulações, para melhor análise das distribuições amostrais.

MODELAGEM USANDO REDES NEURAIS ARTIFICIAIS

Uma rede neural possui, em sua estrutura básica, neurônios na camada de entrada, uma camada interna e nós de saída. Os neurônios da camada de entrada são os parâmetros do **contexto da edificação** e da **descrição do edifício**; e os **nós de saída os parâmetros de desempenho do edifício**. Para a geração dos metamodelos foram realizadas análises quanto a parâmetros importantes na arquitetura da rede, que poderiam ser fundamentais para o desempenho dos modelos. Primeiramente, foram realizados testes segundo o número de neurônios na camada interna da rede. Depois de definidos o número de neurônios que proporcionou o melhor desempenho da rede, partiu-se para a definição de um algoritmo de aprendizagem, e por fim, para a disposição dos parâmetros de saída (nós de saída).

Para todos os testes foram simuladas três redes neurais idênticas, visando garantir que o resultado seria representativo daquela configuração de rede. As arquiteturas de rede foram separadas em: nós de saída de iluminação natural, nós de saída de energia e Todos os nós juntos. Ou seja, foram geradas três configurações de redes neurais a fim de averiguar a possibilidade de uma rede modelar satisfatoriamente os resultados de iluminação natural e energia.

4 RESULTADOS

DEFINIÇÃO DE VARIÁVEIS CHAVES PARA A ILUMINAÇÃO NATURAL RELACIONADAS AO CONSUMO ENERGÉTICO DA EDIFICAÇÃO

Foram levantadas todas as variáveis que se julgou importante para a iluminação natural, relacionada ao consumo de energia, como ilustra a Tabela 1. Neste estudo, fixou-se a cidade de Florianópolis, uma densidade de potência instalada de 12w/m² e uma iluminância alvo de 300 lux.

Tabela 01: Variáveis utilizadas nas simulações

	Variável	Quantidade	Variações
Não amostradas	Localidades	3	Latitude 27º (Florianópolis)
	Densidade de potência em iluminação - DPI (W/m ²)	3	12
	Iluminância alvo (lux)	3	300
1	Refletância das superfícies	3	Combinações (80-80-20; 80-40-20;40-40-20)teto- parede e piso
2	% de abertura na fachada(PAF); Zenital (PAZ)	4	(PAF20,PAF50,PAF80) (PAZ, 2% e 40% 1 abertura ou distribuído em 4 aberturas)
3	Brises	8	Combinações (0;30h;45h;60h;30v;45v;60v;45+45) Onde v: vertical h: horizontal
4	Vidros (Tvis e FS)	6	Tvis: 0,88; 0,43; 0,05;0,5;0,77;0,46;0,12 FS: 0,819;0,602; 0,232; 0,45; 0,468; 0,351;0,299 Obs(último valor usado apenas para abertura zenital de 40%)
5	Orientações	8	N, S, L O, NE, NO, SE, S
6	Densidade de carga interna – DCI (W/m ²)	3	20, 40, 65 (equipamentos + pessoas)
7	Absortância/transmitância	3	Adiabático, pouca troca, média troca (absortância constante)
8	Geometria	3	Proporções: Profundo1/2, isométrico1/1,

			largo2/1 e alto 2.7-5.4
9		4	Dimensões: pequeno, médio e grande. Exemplo das dimensões do Profundo 2mx4m, 4mx8m, 8mx16m
10	Padrão de ocupação	3	8h, 12h, 24h
11	Obstrução externa	4	0° com influência do piso externo, 0° sem influência do piso externo, ângulo de obstrução 40° e 80°
Total de modelos		5.971.968	


Fonte: Autores, 2014.

A combinação de todos os parâmetros gerou 5.971.968 casos, o que tornaria a pesquisa inviável. A possibilidade da amostragem é válida inclusive para uma futura ampliação do método, aplicando-se a mesma amostra para outras localidades, densidades de potência e iluminâncias alvo.

AMOSTRAGEM POR HIPERCUBO LATINO

A amostragem por hipercubo latino gerou 3 conjuntos, um de 100, um de 200 e um de 300 casos, sorteados independentemente. Para os três grupos, cada parâmetro teve o mesmo número de cada valor sorteados o mesmo número de vezes, como mostra a Figura 1.

Figura 01: Número de casos por parâmetros para as amostragens feitas pelo método Hipercubo latino para 100, 200 e 300 casos.



Desta forma, garante-se que todas as amostras seguem as mesmas proporções.

PARAMETRIZAÇÃO DOS MODELOS

A parametrização dos modelos, apesar de bastante trabalhosa, devido ao grande número de parâmetros, permitiu que diferentes amostragens pudessem ser simuladas, utilizando-se o mesmo algoritmo. O algoritmo gerado no Rhinoceros/Grasshopper/DIVA pode ser utilizado para outras amostragens baseadas neste mesmo conjunto de parâmetros.

SIMULAÇÃO INTEGRADA DE ILUMINAÇÃO NATURAL E ENERGIA

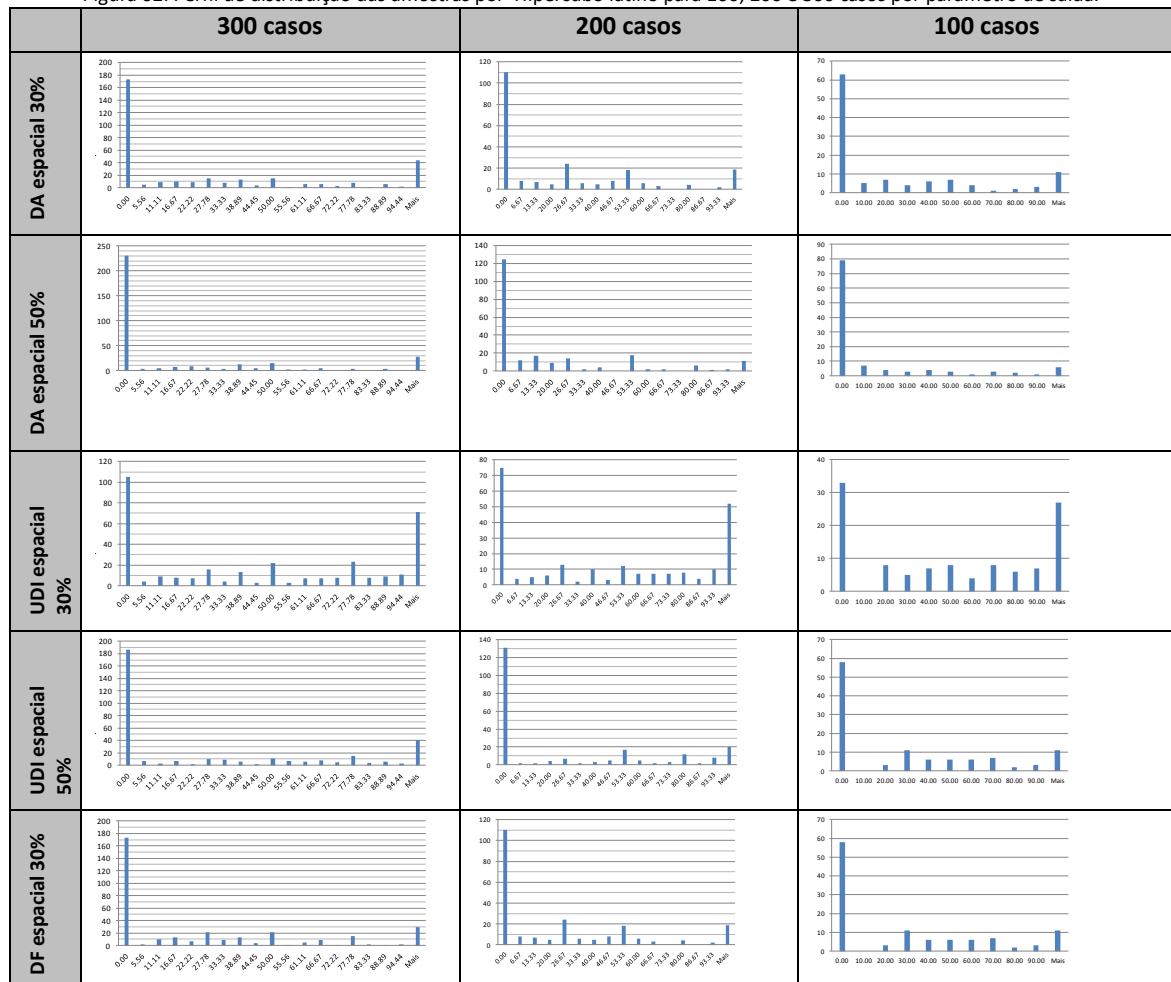
A simulação de iluminação natural é significativamente mais demorada do que a simulação energética. Três computadores foram utilizados para as simulações integradas, com diferentes desempenhos. Os 600 casos (três amostragens) foram divididos em três computadores, com 200 casos em cada um, com tempos de simulações de 12, 16 e 8,5 horas.

TESTE DE NORMALIDADE DAS AMOSTRAS

O teste Kolmogorov-Smirnov foi realizado para cada um dos 11 parâmetros de saída (seis de iluminação natural e cinco de energia) para a amostragem de 300 casos. Com 95% de confiança, todos os conjuntos tiveram a hipótese de normalidade descartada, com exceção do consumo total energético quando testados em escala logarítma.

Diante deste resultado, foram gerados os gráficos de histograma de frequência de ocorrência de todos os parâmetros de saída para as três amostragens, como ilustra Figura 2.

Figura 02: Perfil de distribuição das amostras por Hipercubo latino para 100, 200 e 300 casos por parâmetro de saída.



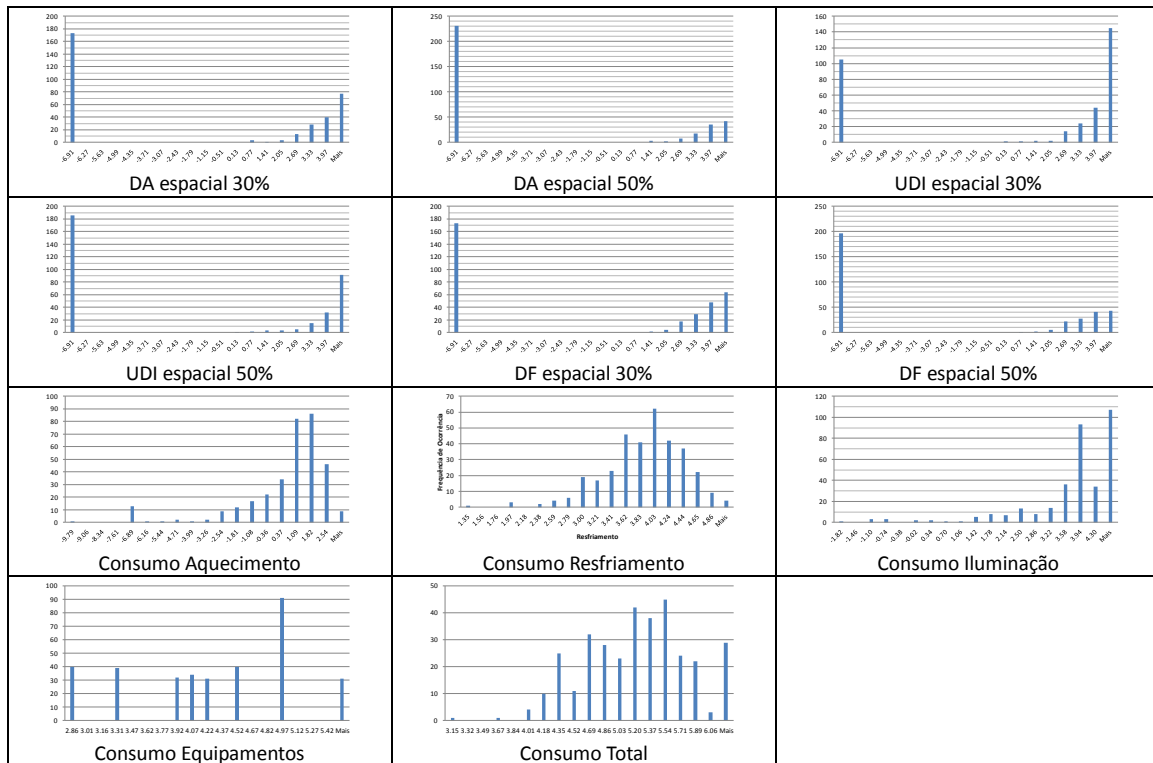


Como se pode observar, apesar de tratar-se de três amostragens independentes, as três possuem o mesmo padrão de distribuição, indicando um bom desempenho da técnica de hipercubo latino. Apesar de todas manterem o mesmo número de ocorrência de cada valor para cada parâmetro de entrada, as combinações dos mesmos poderiam resultar em desempenhos muito diferentes, que poderiam ser amostrados de forma desequilibrada.

As curvas de consumo por resfriamento e aquecimento são as que mais se aproximaram de uma distribuição normal, entretanto, com comportamento assimétrico para a esquerda.

Optou-se, então, pela aplicação da escala logarítma para a amostragem de 300 casos, para verificar uma possível aproximação da distribuição normal. Entretanto, houve um excesso de deslocamento, configurando uma distribuição assimétrica à direita, Figura 3.

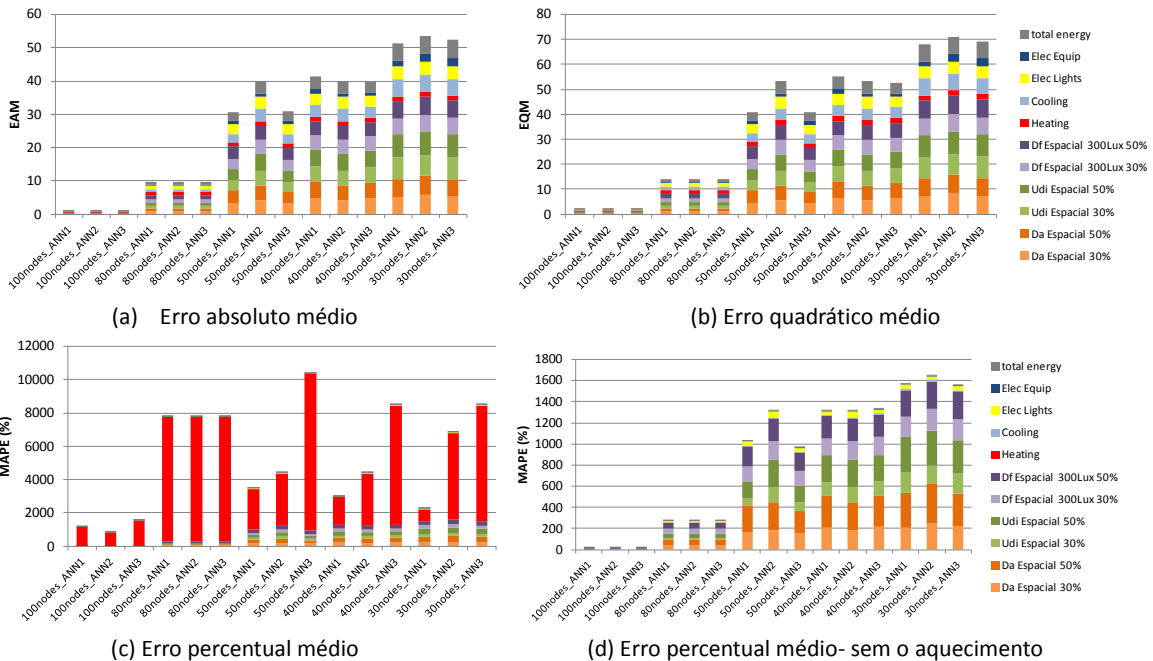
Figura 03: Perfil de distribuição das amostras por Hipercubo latino para 300 casos por parâmetro de saída em escala logarítmica.



MODELAGEM USANDO REDES NEURAIS ARTIFICIAIS


Quanto ao primeiro aspecto avaliado da arquitetura das redes neurais, o número de neurônios na camada interna, pode-se observar uma melhora no desempenho da rede, conforme aumenta o número de neurônios. Não existe um método sólido para a quantificação de neurônios na camada oculta. Alguns grupos de discussão falam em uma vez e meia ou duas vezes o número de nós de entrada. Como a rede tinha 20 nós de entrada (os 11 parâmetros da Tabela 1 tiveram que ser desmembrados para serem lidos pela rede), iniciou-se o modelo com 30 neurônios, passando para 40, 50, 80 e 100 neurônios. A Figura 4 traz os resultados de erro absoluto médio- EAM (a), erro quadrático médio - EQM (b) e erro percentual MAPE (c e d) para cada parâmetro de saída. A escala do eixo das ordenadas é apresentada em kWh/m²/ano para os parâmetros de saída de energia, em percentual de área atendida para os parâmetros de iluminação natural para EAM e EQM. O erro percentual -MAPE (c e d) é dado em percentual para ambos os parâmetros de saída. O gráfico ilustrado na Figura 4 c traz os mesmos dados que o gráfico d, entretanto, neste último foram retirados os erros atribuídos ao consumo por aquecimento para melhor observação dos resultados dos outros parâmetros de saída.

Figura 04: Erros absoluto, quadrático e percentual para diferentes números de nodes na camada interna.



Quanto ao algoritmo de aprendizado, foram testados os algoritmos Bayesian Regularization, Gradiente Descendente e Levenberg Maquardt. O primeiro foi o mesmo utilizado na etapa anterior da análise do número de neurônios na camada interna. A Figura 5 traz os resultados de erro absoluto médio (EAM) e erro percentual (MAPE) para cada parâmetro de saída, para cada um dos três algoritmos. O algoritmo Bayesian Regularization foi o que apresentou melhor desempenho. Apesar de percentualmente parecer apresentar resultado próximo ao Gradiente Descendente (Figura 5 b), quando excluído os valores de consumo por aquecimento, o desempenho gerado é bem mais satisfatório. Apesar do Gradiente descendente apresentar melhor desempenho para modelar o aquecimento, como os valores absolutos deste parâmetro são muito baixos, optou-se por seguir com aplicação do algoritmo Bayesian Regularization.

Figura 05: Erros absoluto e percentual para diferentes algoritmos de aprendizagem



Finalmente, passando para os testes de configuração da rede quanto ao agrupamento dos parâmetros de saída da rede: todos juntos, só iluminação natural e somente energia, pode-se finalizar a análise da aplicabilidade das amostragens.


Apesar dos gráficos das Figuras 6, 7 e 8 apresentarem apenas os resultados para a predição completa da rede, os dados de predição para os valores usados no treinamento, validação e teste também foram avaliados separadamente. Comparando-se as três opções de configuração

de arquitetura da rede: todos os nós de saída, somente os de iluminação natural ou somente os de energia, algumas considerações puderam ser salientadas.

Quanto ao grupo de treinamento, para os dados de saída de iluminação natural, a separação dos nós de saída por natureza aumentou os erros de predição. Apenas as redes baseadas na amostragem de 100 casos não apresentaram alteração significativa nos valores dos erros. Uma possível justificativa seria que as três amostras possuem casos diferentes, e apesar da mesma distribuição de valores de entrada e o mesmo padrão de valores de saída, Figura 7, as diferentes combinações dos parâmetros de entrada podem ser mais representativos dos efeitos da iluminação natural, e de alguma forma, menos dependente da relação com os nós de saída de energia, fazendo que nos ajustes de pesos da rede, a influência dos nós de saída de energia não sejam muito relevantes. Já para os dados de saída de energia, a separação impactou em melhora substancial no desempenho da rede.


Os grupos de validação, teste e a média total da rede seguiram o mesmo padrão quanto à separação dos nós de saída que o grupo de treinamento. Entretanto, o grupo de validação apresentou menor MAPE que o de treino, e por sua vez, o de teste menor ainda, apesar de maiores valores de erro absoluto. A justificativa é que os valores de aquecimento e medidas espaciais de iluminação natural simulados dos conjuntos de treino e validação apresentaram muitos valores próximos à zero, fazendo com que o erro absoluto repercutisse em um elevado erro percentual, elevando o MAPE do conjunto. Já o conjunto de teste apresentou elevados valores de áreas iluminadas segundo os critérios estabelecidos e valores de aquecimento entre 2e 4 kWh/m/ano.

Figura 06: Erros percentual, absoluto e quadrático para a configuração de todos os parâmetros de saída em uma mesma rede.



Os valores de MAPE dos gráficos das figuras 6 e 8 foram mascarados pelos elevados valores de erro para aquecimento. No entanto, estes valores não devem ser considerados, visto que em valores absolutos são extremamente baixos. Desconsiderando-se os valores de MAPE para aquecimento, os maiores erros percentuais ocorreram para o consumo referente à iluminação. Entretanto, os valores de MAPE para iluminação, para o conjunto de teste, para as redes com todos os nós de saída, não ultrapassaram 7%, enquanto que os demais valores para nós de saída de energia não ultrapassaram 2% cada um. Quando os erros dos nós de saída de energia foram observados separadamente, o MAPE não ultrapassou 0,25% para a amostra de 100 casos e 0,05% para a amostra de 300 casos. Sendo que neste caso, grande parte dos erros são atribuídos ao consumo por iluminação. Mesmo assim, este erro pode ser considerado extremamente baixo, na ordem de 0,04 kWh/m²/ano. Já os erros para as redes com todos os nós de saída juntos para iluminação natural foram da ordem de 2,5% para a amostra de 200 casos e 3,5% para a amostra de 100 casos, sendo que, quando cada nó de saída foi observado separadamente, o erro foi de 0,3% e 0,6%, respectivamente.


Figura 07: Erros percentual, absoluto e quadrático para a configuração para os parâmetros de saída de iluminação natural.




Observando os nós de saída de iluminação natural, pode-se constatar que, para o conjunto de teste, os maiores erros foram para o parâmetro UDI espacial, sendo que UDI_espacial_30% apresentou erros maiores que UDI_espacial_50%, tanto para erros absolutos quanto para percentuais. Já para a rede como um todo, os maiores erros foram para DF espacial, não havendo diferenciação entre DF_espacial_50% e DF_espacial_30%. Esta constatação pode ser observada tanto nas redes com todos os nós de saída agrupados quanto para as redes de nós de saída exclusivos de iluminação natural.

Pode-se observar também que, para esta configuração de rede, a amostra de 300 casos se mostrou mais irregular, quando considerados os resultados das três redes neurais rodadas, Figura 6. Enquanto que a ANN3 para 200 casos apresentou erros significativamente fora do padrão. Este resultado justifica-se pelo fato de que cada ANN inicia seu processo de ajuste de pesos de um ponto aleatório da superfície do erro. Esta rede traçou um caminho notadamente diferente das outras duas, neste caso esta rede poderia ser desconsiderada. Esta observação frisa a importância da simulação de várias redes com a mesma configuração evitando-se trabalhar com resultados que não expressem o potencial da rede.


Figura 08: Erros percentual, absoluto e quadrático para a configuração para os parâmetros de saída de consumo energético.



(a) Erro percentual médio



(b) Erro absoluto médio



(c) Erro absoluto médio

Quanto ao desempenho das redes relacionadas ao tamanho das amostras, as redes com nós de saída exclusivos de energia apresentaram o padrão esperado, com erros decrescentes conforme se aumentava o número de casos nas amostras. Com exceção do aquecimento, que apresentou valores de MAPE elevados para as redes baseadas em amostras de 200 casos, porém excluindo-se os valores de erro para aquecimento, os demais nós de saída apresentaram a mesma tendência. Apenas uma ANN das três da mostra de 300 casos apresentou MAPE fora do padrão para o grupo de validação com erros maiores que a amostra de 200 casos.

5 CONCLUSÕES

Para a definição de um método seguro de definição do número de amostras para modelagem usando redes neurais artificiais, foram primeiramente definidas as variáveis chaves para o consumo energético, sob o enfoque da iluminação natural.

Foram então definidos parâmetro do contexto, da definição e do desempenho do Edifício. Estes parâmetros foram combinados e gerados modelos que foram amostrados utilizando-se a técnica Hipercubolativo. Foram realizadas três amostragens, de 300, 200 e 100 casos. Os modelos foram parametrizados e simulados através de simulação integrada (Rhino, Grasshopper e DIVA - Daysim+ Energyplus). Solicitaram-se dados de saída referentes à iluminação natural e consumo energético. Estes dados foram utilizados para o treinamento, validação e teste de diferentes configurações de redes neurais artificiais.

Como principais conclusões, as redes tiveram melhor desempenho com cerca de 100 neurônios na camada intermediária e com o algoritmo de aprendizagem Bayesian regularization. O aumento do número de neurônios aumenta também o tempo de processamento, que variou entre 30 minutos para trinta neurônios e até 4 horas para 100 neurônios, em um dos computadores.

A diferença entre o agrupamento dos parâmetros de saída mostrou comportamentos distintos para os parâmetros de iluminação natural e energia, posto que os erros na predição nos parâmetros de saída de iluminação natural foram maiores quando utilizados separadamente, ao passo que os erros dos parâmetros de energia reduziram muito.

Como conclusão final, as três amostras apresentaram resultados de erros baixos, quando excluído o MAPE do aquecimento. Logo, em todos os outros casos, indica-se fazer um balanço entre tempo de processamento das redes e os erros, pois os valores de erros obtidos permitiram o uso de qualquer uma das três amostras, indicando-se para a amostra de 200 casos por ser mais conservadora que a de 100 casos, mas demandar menos tempo de processamento que a de 300 casos. O agrupamento de nós de saída apresentou influência significativa, possivelmente pela relação de ajuste de pesos da rede conforme os nós de saída. A piora no desempenho dos nós de saída de iluminação, com a separação dos nós, e a melhora por parte dos nós de energia, merece maiores investigações. Entretanto aponta-se por uma dependência de algum nó de energia para o melhor desempenho dos de iluminação natural, muito provavelmente o de consumo em iluminação.

REFERÊNCIAS

- BARTLETT, J. E., KOTRLIK, J. W. e HIGGINS, C. C. Organizational Research: Determining Appropriate Sample Size in Survey Research. *Information Technology, Learning, and Performance Journal*, v.19, n.1, Spring - 2001, p.43-50. 2001.
- BOCANEGRA, C. W. R. Procedimento para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes. (dissertação de mestrado). Departamento de Engenharia Civil, Universidade de São Paulo, São Carlos, 2002. 97 p.
- COSTA, G. C. F. Uma avaliação do consumo de energia com transportes em cidades do estado de São Paulo. (dissertação de mestrado). Departamento de Engenharia Civil, Universidade de São Paulo, São Carlos, 2001. 103 p.
- FORSECA, R. W.; DIDONÉ, E. L. ; PEREIRA, F. O. R. . Using artificial neural networks to predict the impact of daylighting on building final electric energy requirements. *Energy and Buildings*, v. 61, p. 31-38, 2013.
- HAYKIN, S. *Redes Neurais: Princípios e Práticas*. Porto Alegre: ARTMED Editora S.A. 2001. 900 p.
- IES LM-83-12. (2012). Approved Method: IES Spatial Daylight Autonomy (sDA) and Annual Sunlight Exposure (ASE)- IES LM-83-12. Nova Iorque: Illuminating Engineering Society of North America.
- JAKUBIEC, J. A., REINHART, C. (2011). THE "ADAPTIVE ZONE" -- A CONCEPT FOR ASSESSING GLARE THROUGHOUT DAYLIT SPACES. In *Proceedings of Building Simulation 2011:12th Conference of International*



Building Performance Simulation Association (pp. 14–16). Sydney.

MASCHIO, C., CARVALHO, C. P. V. e SCHIOZES, D. J. Aplicação da técnica de hipercubo latino na integração do ajuste de histórico com a análise de incertezas. 5 Congresso Brasileiro de Pesquisa e Desenvolvimento em Petróleo e Gás. Fortaleza/ Ceará: Associação Brasileira de P&D em Petróleo e Gás 2009.

MATLAB Mathworks R2014a disponível em <<http://www.mathworks.com/help/stats/lhsdesign.html>> consultado em julho de 2014

MELO, Ana Paula. Desenvolvimento de um método para estimar o consumo de energia de edificações comerciais através da aplicação de redes neurais. Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Pós-Graduação em Engenharia Civil- Florianópolis, SC, 2012. 189 p.

MCNEEL, R: 2010, Rhinoceros – NURBS Modelling for Windows (version 4), McNeel North America, Seattle.

REINHART, C. F. 2010, Tutorial on the Use of Daysim Simulations for Sustainable Design, Harvard University, Cambridge.

RIBEIRO, J. L. D. e CATEN, C. S. T. Série Monográfica Qualidade - Projeto de Experimentos Porto Alegre, RS: Universidade Federal do Rio Grande do Sul 152 p. 2011.

RISSO, V. F., RISSO, F. V. A. e SCHIOZER, D. J. Aplicação da técnica do hipercubo latino no treinamento de redes neurais na análise de risco de campos de petróleo. Rio Oil and Gas Expo and Conference 2010. Rio de Janeiro/Brasil: Rio Oil and Gas Expo and Conference 2010.

RUTTEN, D., 2011, “Evolutionary Principles Applied to Problem Solving”, Available from: David Rutten’s blog <<http://ieatbugsforbreakfast.wordpress.com/2011/03/04/epatps01/>> (acesso em 15 de julho de 2014).

ZERPA, L. E., et al. An optimization methodology of alkaline-surfactant-polymer flooding process using field scale numerical simulation and multiple surrogates. Journal of Petroleum Science and Engineering, v.47, p.197-2008. 2005.