

SEQUÊNCIA METODOLÓGICA PARA A ESTIMATIVA DA CONTRIBUIÇÃO DA ILUMINAÇÃO NATURAL NA REDUÇÃO DO CONSUMO ENERGÉTICO DE EDIFICAÇÕES

Raphaela Walger da Fonseca (1); Fernando Oscar Ruttkay Pereira (2)

(1) Arquiteta, Pós-doutoranda do Programa de PósARQ/UFSC, raphawf@gmail.com

(2) PhD, Professor do Departamento de Arquitetura e Urbanismo, feco@arq.ufsc.br

Universidade Federal de Santa Catarina, Departamento de Arquitetura e Urbanismo, Laboratório de Conforto Ambiental, Cx Postal 476, Florianópolis - SC, 88040-900, Tel.: (48) 3721-4974

RESUMO

Existem inúmeras evidências dos benefícios atribuídos à iluminação natural. Estudos encontrados na literatura indicam o elevado potencial para o uso de redes neurais artificiais (RNA) para estimar o consumo energético em edifícios, inclusive, considerando a iluminação natural. Neste sentido, o objetivo deste trabalho foi propor uma sequência metodológica integrando o uso de RNA com zoneamento de iluminação natural para a estimativa da redução do consumo energético de edifícios não residenciais em função do aproveitamento desta fonte de luz. A abordagem utilizada foi a metamodelagem, sendo as redes treinadas com base em resultados obtidos através de simulações computacionais energéticas. Devido ao grande número de casos paramétricos, utilizou-se a técnica de amostragem Hipercubo Latino para gerar os dados de entrada para as simulações integradas realizadas no plug-in DIVA do programa Rhinoceros. As simulações foram feitas propondo-se um algoritmo desenvolvido no plug-in Grasshopper. Para a aplicação do método, propôs-se a utilização de uma RNA, tendo como parâmetro de saída Densidade de Potência de Iluminação em Uso, combinada com zonas de iluminação natural através de ponderação por área. As zonas foram propostas com base em equações que consideraram o dinamismo do clima. O trabalho discute esta abordagem e o RTQ-C e indica o desenvolvimento do método que apresentou erros inferiores a 5%. Como conclusão geral, pode-se dizer que as RNAs são uma técnica com potencial para ser aplicada no desenvolvimento de métodos simplificados de iluminação natural sob o enfoque energético, desde que otimizadas segundo o ajuste dos parâmetros da arquitetura da rede, ajuste das amostras de treinamento e testes com casos nunca apresentados à rede.

Palavras-chave: iluminação natural, consumo energético, redes neurais artificiais, método simplificado.

ABSTRACT

There are numerous evidences of daylighting benefits. Studies in the literature indicate the high potential for artificial neural networks (ANN) application to estimate the energy consumption in buildings, even considering daylighting harvesting. In this sense, the main goal of this study was to propose a methodological sequence integrating the use of ANN with a daylighting zoning aiming to predict the potential of energy savings for non-residential buildings due to the use of this renewable source. The approach used in this study was metamodeling, and the networks were trained based on results that were obtained through energy computer simulations. Due to the large number of parametric cases, the Latin Hypercube sampling technique was used to generate the input data for the integrated simulations carried out in the DIVA plug-in for the Rhinoceros software. The simulations were executed proposing an algorithm that had been developed in the Grasshopper plug-in. The use of an ANN was proposed as a method application, where the output parameter was Lighting Power Density in Use, combined with daylighting zones weighted by area. The zones were proposed based in equations that consider the weather dynamism. In addition, the paper discuss the methodological sequence approach related to the RTQ-C and indicates the method development with presented errors than lower 5%. As a general conclusion, it can be stated that the ANN are a technique that shows a potential for being applied to develop simplified daylighting methods in line with the energy approach, provided that they are optimized according: network parameters adjusting, training samples adjusting and tests using cases not-known by the network.

Keywords: daylighting, energy consumption, artificial neural networks, simplified method.

1. INTRODUÇÃO

Nos últimos anos, quando se começou a falar mais sistematicamente sobre conservação e racionalização do uso da energia elétrica nos edifícios, o aspecto da integração entre luz natural e artificial passou a assumir importância cada vez maior. Existe um grande número de pesquisas que mostram a preferência pela luz natural como fonte de luz em edifícios (MAYHOUB e CARTER, 2010). Este fato deve-se a uma série de fatores relacionados com o cumprimento das necessidades biológicas humanas (CIE, 2003). Além do potencial de conservação energética (WILLIAMS, 2012).

Assaf e Pereira (2003) definiram a eficiência energética de um sistema de iluminação como a capacidade de um sistema conversor transformar a energia elétrica em condições de visão, conforto e atmosfera visual. Entendendo que a energia é função da potência e do tempo, reduzindo-se uma dessas duas variáveis, reduz-se o consumo energético. O aproveitamento da iluminação natural está diretamente relacionado à redução do tempo de acionamento.

A eficiência das instalações de iluminação artificial é mais fácil de ser mensurada que as de iluminação natural, pois se trata de um sistema estático. Embora haja discussões sobre a adequabilidade dos indicadores existentes em garantir um ambiente bem iluminado, essa limitação está mais relacionada com a dificuldade de definir e mensurar a qualidade da iluminação. Os mesmos autores propõem um índice que relaciona a eficiência da lâmpada, do equipamento auxiliar, da luminária e do desenho da instalação e citam mais dois índices: Densidade de Potência de Iluminação (DPI), definido como a potência (W) por unidade de superfície do ambiente iluminado (m^2); e Potência Específica de Iluminação – Pei, que utiliza a densidade de potência de iluminação necessária para produzir uma iluminância horizontal de 100 lux por unidade de superfície ($W/m^2 \cdot 100 \text{ lux}$). O primeiro é utilizado pelas normas americanas ASRHAE/IES 90.1 (ASHRAE, 2013) e TITLE 24 (CALIFORNIA ENERGY COMMISSION, 2013) e pelo regulamento brasileiro RTQ-C (INMETRO, 2010), já o segundo pelo código britânico PART-L (EPBD-NCM, 2014). É importante notar que nenhum desses índices inclui a variável tempo de uso, a qual estaria relacionada à iluminação natural. Normalmente, esses índices são combinados com algumas considerações sobre sistemas de controles e zoneamento de iluminação natural.

Muitos autores já comprovaram o potencial de aproveitamento da iluminação para a conservação de energia em edifícios comerciais. Em levantamento bibliográfico realizado por Fonseca (2015) foram encontrados percentuais de economia do sistema de iluminação artificial variando entre de 20% e 80% e entre 12 e 52% para o consumo global.

Métodos simplificados de avaliação de iluminação natural são importantes ferramentas idealizadas para serem utilizadas em especial nas fases iniciais de projeto, em que as principais decisões estão sendo tomadas (PEREIRA, et al, 2005). Estas ferramentas são idealizadas para dar respostas rápidas sem necessitar significativo detalhamento de informações. Normalmente são utilizadas para comparar o desempenho de diferentes soluções de projeto podendo ser utilizadas para avaliações prescritivas de projetos já concluídos, com o objetivo de classificar o desempenho do projeto.

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 prescritivas, como exemplo no cenário nacional, o RTQ-C¹. Entretanto o uso de Regressão Não Linear Multivariada (RLM) 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 engenharia devido a sua boa resposta para modelos não lineares (BOCANEGRA, 2002).

As redes neurais artificiais são técnicas computacionais baseadas em modelos matemáticos que utilizam inteligência artificial e que, assim como os demais modelos, objetivam representar ou aproximar sistemas (HAYKIN, 2001). Segundo Wong, Wan e Lam (2010), as RNA oferecem melhores respostas para edifícios com os padrões de utilização de energia altamente não lineares, além de melhores correlações e menores erros para a aproximação de funções que outras técnicas como a RLM (BOCANEGRA, 2002). A popularidade das RNA para modelar o desempenho de edifícios vem crescendo nas últimas décadas. A exemplo disso, vários trabalhos apresentam um panorama do uso dessa técnica para a modelagem energética de edifícios (KALOGIROU, 2001; KRARTI, 2003; ZHAO, H.-X. e MAGOULÈS, 2012). É importante ressaltar que apenas 11 anos antes, Kalogirou (2001) utilizou alguns poucos exemplos de aplicações de RNA

1 O RTQ-C – Regulamento Técnico da Qualidade para o Nível de Eficiência Energética de Edifícios Comerciais, de Serviços e Públicos –, de abrangência nacional, foi publicado através da Portaria n. 163, de 8 de junho de 2009, como parte do Programa Brasileiro de Etiquetagem do Instituto Nacional de Metrologia, Qualidade e Tecnologia (INMETRO). Atualmente, a portaria vigente é a Portaria n. 372, de 17 de setembro de 2010, com três portarias complementares: Portaria n. 17, de 16 de janeiro de 2012; Portaria n. 299, de 19 de junho de 2013; e Portaria n. 126, de 18 de março de 2014.

para a predição do consumo energético, enquanto Zhao e Magoulès (2012) apresentaram mais de 50. Esse crescimento pode ser justificado pelos resultados satisfatórios que essa técnica vem apresentando no campo de estudo. Devido a sua capacidade de modelar relações não lineares as RNA também têm apresentado potencial para modelar desempenho energético considerando a iluminação natural (WONG, WAN e LAM, 2010 e FONSECA, DIDONÉ e PEREIRA, 2015).

No sentido de avançar na aplicação de RNAs em avaliações energéticas, este trabalho visa propor uma sequência metodológica que integra o uso de RNAs com zoneamento de iluminação natural para estimar impacto do aproveitamento da iluminação natural no consumo energético de edificações. Para tal utilizou-se uma base de modelos paramétricos (FONSECA, 2015) que utiliza variáveis chave da iluminação natural combinadas e amostradas através da técnica de amostragem do Hipercubo Latino. Depois de selecionados, os modelos foram preparados para a simulação integrada (Rhinoceros, Grasshopper e DIVA: Daysim + Energyplus) (FELIPPE et al, 2015). Estas simulações foram utilizadas para propor uma RNA que pudesse estimar um índice de redução do uso da densidade de potência instalada (IR_{ILN}), seja pela redução do tempo de acionamento ou pela redução da intensidade através da utilização de *dimmers*. Este índice deve permitir a verificação da Densidade de Potência em Uso (DPU), atribuída ao potencial de aproveitamento da iluminação natural. Para a proposta do método simplificado o IR_{ILN} foi aplicado a um zoneamento de iluminação natural dinâmico que permite estimar a profundidade e a largura das zonas de iluminação natural (FONSECA, 2015). Nesta proposta, o índice IR_{ILN} é ponderado pelas áreas de iluminação natural a fim permitir a estimativa da redução do consumo energético referente à iluminação em ambientes que se beneficiam desta fonte renovável de energia.

2. OBJETIVO

O objetivo deste trabalho é propor uma sequência metodológica para estimar o impacto da luz natural no consumo energético de edificações através da aplicação de RNAs para determinação da DPU associada a um zoneamento de iluminação natural

3. MÉTODO

O método deste trabalho consiste em três etapas. A primeira trata da integração de uma RNA com uma proposta de zoneamento de iluminação natural lateral. A segunda averigua o erro inerente à proposta comparada à simulação computacional do modelo. Por fim, avalia-se o impacto da aplicação do método em um sistema de avaliação de eficiência energética de edificações, utilizando como estudo de caso o RTQ-C.

3.1 Integração de uma RNA ao zoneamento de Iluminação Natural

O método utilizado consiste na aplicação do índice IR_{ILN} gerado a partir de uma RNA aplicado ao zoneamento dinâmico de iluminação natural (FONSECA, 2015). O índice IR_{ILN} permite o cálculo da DPU corresponde ao percentual da DPI que precisa ser acionada, ou seja, se o IR_{ILN} é 60%, significa que é necessário acionar apenas 60% da DPI para determinado ambiente em função do aproveitamento da luz natural. Para a determinação da DPU do ambiente todo, pondera-se o IR_{ILN} obtido para a Zona de Iluminação Natural pela DPI (DPU 100%) aplicada ao restante da área. Esse processo pode ser repetido com base em cada janela do ambiente. Neste trabalho, a sequência descrita será demonstrada através de um exemplo de aplicação do método.

Com a intenção de que o método simplificado pudesse ser utilizado em ambientes de geometrias variadas e com diferentes quantidades e distribuições de janela, optou-se por considerar a DPU aplicada a cada zona. Cada zona corresponde a uma janela. A definição das zonas de iluminação natural baseia-se na Autonomia da Luz Natural (DA) definida como o percentual de horas ocupadas em que um nível mínimo de iluminância no plano de trabalho pode ser garantido apenas pela iluminação natural. A Zona 1 é definida como área em que a iluminância de projeto é atendida em 50% das horas do ano (DA= 50%) e a Zona 2 em 30% das horas do ano (DA= 30%) (FONSECA, 2015).

O IR_{ILN} da Zona 1 corresponde ao IR_{ILN} fornecido pela RNA; logo, os parâmetros de entrada relativos à dimensão da zona utilizados como entrada para a RNA devem corresponder aos obtidos para a Zona 1 através do cálculo proposto para o zoneamento. O IR_{ILN} da Zona 2 corresponde ao IR_{ILN} obtido pela RNA para a Zona 1, multiplicada pelo Fator de Ajuste do IR_{ILN} (FONSECA, 2015), pois as simulações utilizadas para o treino da rede neural consideraram o IR_{ILN} do modelo de maneira geral, não sendo possível determinar IR_{ILN} separados por zonas. Definidas as dimensões das zonas e seus respectivos IR_{ILN} , ponderaram-se os

IR_{ILN} pelas respectivas áreas e pela DPI do restante do ambiente (área não atingida pelas zonas de iluminação natural).

A RNA utilizada para a estimativa do IR_{ILN} foi proposta com base na técnica de validação cruzada *multi-fold* e foi definida segundo as seguintes etapas:

- normalização dos dados segundo a função de transferência adotada;
- determinação do tipo de rede e do algoritmo de treinamento para proceder a sua inicialização; no caso deste estudo, foi adotada uma MPL alimentada adiante com Gradiente Descendente baseado na retropropagação do erro;
- definição do número de neurônios na camada intermediária, determinados através de testes;
- determinação das funções de transferência, tendo sido adotada a função logarítmica sigmoidal (*logsig*²).

Os parâmetros de treinamento da rede, tais como gradiente mínimo³, número máximo de épocas⁴, erro final desejado e taxa de aprendizado⁵, foram definidos segundo a bibliografia e a experimentação. Para a utilização da validação cruzada o conjunto de dados é dividido em dois subconjuntos. O primeiro é o subconjunto de treinamento e consiste nos exemplos apresentados à rede. E o segundo é o subconjunto teste. O subconjunto teste tem 10% a 20% do conjunto de treinamento; no caso deste trabalho, foram adotados 10%. O conjunto de dados original de N exemplos é, então, dividido em K subconjuntos, onde $K > 1$. O treinamento do modelo ocorre em todos os subconjuntos, exceto em um, e o erro de validação é medido testando-o sobre o subconjunto deixado de fora. O procedimento descrito é repetido por K tentativas, cada vez utilizando um subconjunto de teste diferente (HAYKIN, 2001).

A seleção de dados para cada subconjunto é feita de forma randômica. Para o presente trabalho, foram realizadas $K = 10$ tentativas. As simulações foram realizadas no programa MATLAB, do qual foram obtidos o coeficiente de correlação de cada uma das 10 configurações do subconjunto de treinamento e os erros absoluto (MAE) e quadrático médio (RMSE) de cada um dos 10 subconjuntos de teste. Com isso, foi possível averiguar a capacidade da rede em predizer resultados de saída. A escolha da rede a ser utilizada foi feita com base no maior coeficiente de correlação e no menor erro quadrático médio (RMSE).

3.1 Verificação do erro da proposta apresentada

Para a verificação dos erros inerentes à aplicação conjunta do metamodelo baseado em redes neurais artificiais com modelos de regressão exponencial, três verificações foram feitas:

- i. verificação do erro inerente às equações de zoneamento dinâmico utilizadas no exemplo;
- ii. comparação do resultado previsto pela RNA para a Zona 1 com o resultado simulado para a mesma zona; e
- iii. comparação do resultado do método prescritivo com o resultado simulado para o ambiente todo.

3.2 Impacto do aproveitamento da Iluminação Natural na classificação de eficiência energética

Para avaliar o impacto da consideração da iluminação natural em avaliações de eficiência energética, utilizou-se o resultado da DPU do exemplo de aplicação aqui discutido e comparou-se com resultados encontrados por Scalco et al (2015). No referido estudo, os autores desenvolveram uma investigação sobre *retrofit* de sistema de iluminação em doze edifícios de escritórios. Sistemas de iluminação classe D (DPI de 14,1 W/m²), segundo método da etiqueta PBE Edifica, foram substituídos por sistemas classe A (DPI de 9,7 W/m²) e por um sistema de LED com DPI de 5,4 W/m², baseado em um valor médio para sistemas de LED eficientes obtidos na bibliografia.

A comparação foi feita de forma gráfica em valores percentuais e visou avaliar o potencial de economia de energia em kWh/m²/ano e de impacto na classificação de eficiência energética segundo a etiqueta PBE Edifica.

² *Logsig*: função de transferência logarítmica sigmoidal do MATLAB. Calcula o valor da saída do neurônio a partir das entradas do *net*, ou seja, o valor que será transferido para a próxima camada, utilizando uma função logarítmica sigmoidal que varia entre 0 e +1. Possui formato de “S”, sendo uma função não linear.

³ Gradiente mínimo de descida: determina um vetor de pesos que minimiza o erro; o parâmetro gradiente mínimo estabelece o desempenho mínimo desse gradiente.

⁴ Épocas: número de interações para o treinamento.

⁵ Taxa de aprendizado: geralmente varia entre 0,1 e 1. Quanto mais baixo for o seu valor, mais lento será o aprendizado.

4. RESULTADOS

Os resultados do método proposto são apresentados na forma de um exemplo de aplicação. Para tal foi considerado um ambiente de 5,2 m por 6,65 m com pé-direito de 3 m e a altura da verga de 2,4 m, ver Figura 1. Para a obtenção do IR_{ILN} , treinaram-se RNAs baseadas em simulação computacional energética integrada (FELIPPE, et al., 2015), considerando a cidade de Florianópolis. O método da validação cruzada foi aplicado com $K = 10$ tentativas, para a escolha da RNA, compararam-se as 10 RNAs simuladas e escolheu-se a RNA 9. Foram avaliados os desempenhos no treinamento, no teste e na avaliação da zona usada nesse teste. Os resultados de desempenho obtidos para essa rede são apresentados na Tabela 1.

Tabela 1 – Desempenho da RNA 9 para os conjuntos de treino teste e da janela 1

Referente ao treino		Conjunto de treino simulado pela rede		Conjunto de teste		Zona 1	
r^2	0,9801	MAE	3,2815	MAE	4,1311	MAE	0,5025
r	0,9892	DesvPad MAE	2,7169	DesvPad MAE	4,7597	MAPE	7,4139
MAE_{NORM}	0,0316	RMSE	4,2599	RMSE	6,2951		
$RMSE_{NORM}$	0,0403	MAPE	8,3622	MAPE	9,0490		

4.1 Sequência para determinação da DPU do ambiente

O método aqui proposto é composto de quatro passos, apresentados a seguir.

1º PASSO: definição da profundidade das zonas

Para a escolha da equação, devem-se determinar primeiro a iluminância alvo e o PAF. A iluminância alvo utilizada nesse exemplo será de 500 lux. A determinação do PAF deve ser feita como se a largura da parede coincidisse com a largura da janela. Isso porque os modelos simulados tanto para o zoneamento quanto para a RNA consideraram janelas em fita. Para o cálculo do PAF, a área de fachada foi considerada o produto entre o pé-direito do ambiente (3 m) e a largura da Janela 1 (2,25 m), resultando em 6,75 m². A área da Janela 1 corresponde a 5,4 m², logo o PAF resultou em 80%. Adotaram-se as equações para PAF 80%, para Zona 1 ver Equação 1 e para Zona 2 ver Equação 2. Como refletância das superfícies, utilizaram-se 20% para piso, 40% para parede e 80% para o teto. Já a autonomia da luz natural a ser alcançada foi de 50% referente ao limite mínimo da Zona 1 e 30% referente à Zona 2. Esses dados foram compilados na Tabela 2.

Tabela 2 – Dados de entrada utilizados para as equações da determinação da profundidade das zonas Z1 e Z2

ZONA	PAF (%)	Iluminância alvo (lux)	T _{vis}	ORIENTAÇÃO (°)	1/DA _{MIN}	1/ (1-r _{média})
Z1 (DA 50%)	80	500	0,80	90	0,02	1,79
Z2 (DA 30%)	80	500	0,8	90	0,03	1,79

A seguir são apresentadas as equações para a Zona 1 ver Equação 1 (FONSECA, 2015) e para a Zona 2 (Z1+Z2) ver Equação 2 (FONSECA, 2015).

$$2 * AREA_{ZONA} = EXP[(0,5743 * T_{VIS}) + (0,0002 * ORIENT) + (77,3417 * \frac{1}{DA}) + (0,0008 * \frac{1}{(1 - R_{MEDIA})})] \quad (1)$$

$$2 * AREA_{ZONA} = EXP[(0,5804 * T_{VIS}) + (0,0002 * ORIENT) + (49,2281 * \frac{1}{DA}) + (0,0006 * \frac{1}{(1 - R_{MEDIA})})] \quad (2)$$

Como resultado da aplicação da Equação 1, a Zona 1 ficou com 2,96 m de profundidade; e, como resultado da aplicação da Equação 2, a Zona 2 (Z1+Z2) ficou com 4,02 m de profundidade.

2º PASSO: definição da largura das zonas

Para a definição das larguras das zonas, aplica-se a Equação 3 (FONSECA, 2015). Os índices de largura de zona (i_{LZ}) utilizados na equação são obtidos de acordo com Fonseca (2015). A Tabela 3 ilustra os dados de entrada utilizados na equação para as zonas Z1 e Z2.

$$L_{ZONA} = (H_{VERGA} * L_{JANELA}) * i_{LZ} \quad (3)$$

Onde:

L_{zona} : largura da zona para cada lado a partir da aresta da janela (m);

H_{verga} : altura da verga em relação ao piso (m);

L_{janela} : largura da janela em si (m); e

i_{LZ} : índice de largura de zona (adimensional).

Aplicando-se a Equação 3 chega-se a uma largura de zona medida a partir da aresta da janela de 0,69 m para a Zona 1 e de 1,22 m para a Zona 2. Multiplicando-as pelas duas laterais, já que não existe nenhum obstáculo físico que impeça a distribuição da luz, e somando-se a largura real da janela, obtém-se a largura das respectivas zonas. Como resultado, a largura total da Zona 1 (L_{ZONA}) resultou em 3,63 m e a largura total da Zona 2 (L_{ZONA}) resultou em 4,17 m. O resultado do zoneamento pode ser visto na Figura 1.

Tabela 3 – Dados de entrada utilizados para as equações da determinação da largura das zonas Z1 e Z2

ZONA	H_{verga} (m)	L_{janela} (m)	$H_{verga} * L_{janela}$ (m ²)	i_{LZ}
Z1 (DA 50%)	2,4	2,25	5,4	0,1281
Z2 (DA 30%)	2,4	2,25	5,4	0,2265

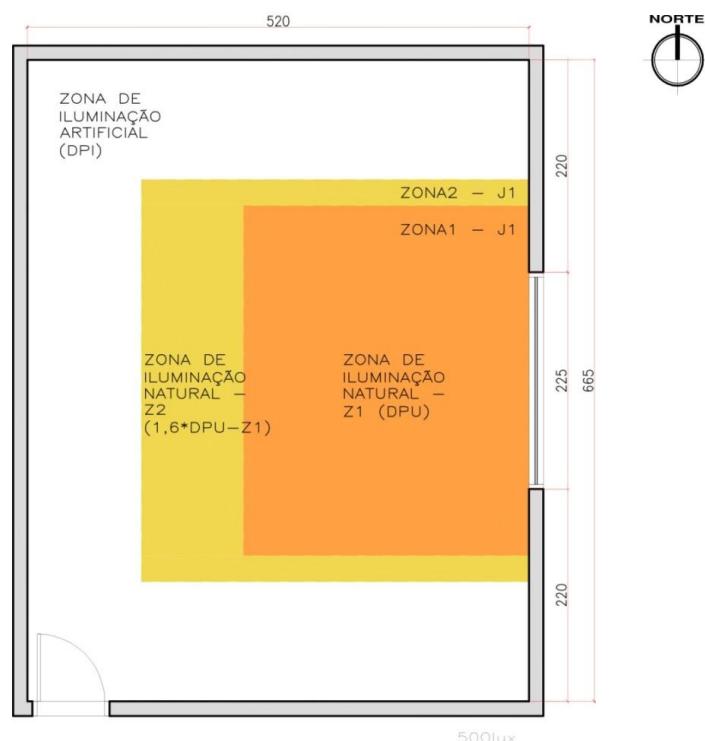


Figura 1 – Aplicação do zoneamento

3º PASSO: cálculo da DPU baseada na RNA

Para determinar o IR_{ILN} da Zona 1, utilizaram-se como valores de entrada para a RNA de acordo com a Tabela 4.

Tabela 4 – Dado de entrada utilizado na RNA para obtenção da DPU

VARIÁVEL	VALOR ADOTADO	VARIÁVEL	VALOR ADOTADO	VARIÁVEL	VALOR ADOTADO
Refletância Teto	80	T_{VIS}	0,88	Largura	2,96
Refletância Parede	40	FS	0,819	Profundidade	3,63
PAF	80	Orientação	90	Altura	3
PAZ	0	DCI_equipamentos	15	Ocupação	12
PAZ: abertura única	0	DCI_pessoas	0,53	Ângulo de obstrução	0
PAZ: abertura distribuída	0	Transmitância	2	Influência do piso externo	0
Proteção solar horizontal	0			DPI	12
Proteção solar vertical	0			Iluminância Alvo	500

A RNA 9 (ver Tabela 1) escolhida para esse exemplo retornou IR_{ILN} de 6,28%_{DPI}. Para a determinação do IR_{ILN} da Zona 2, aplica-se o Fator de Ajuste de IR_{ILN} para Zona 2 (FA_{DPU}) igual a 1,6, de acordo com Fonseca (6). Multiplicando-se o IR_{ILN} da Zona 1 pelo FA_{IRILN} para a Zona 2, obteve-se 10,04%_{DPI} como IR_{ILN} para a Zona 2.

4º PASSO: ponderação da IR_{ILN} da zona 1 pela DPI do ambiente

Neste passo, calculam-se a área das zonas Z1 e Z2 e a área remanescente do ambiente em que o aproveitamento da iluminação natural não é computado ($IR_{ILN} = 100\%$, ou seja, DPI acionada em 100% das horas de ocupação com 100% de intensidade). A área remanescente será chamada de Zona DPI (Z_{DPI}). A obtenção da IR_{ILN} do ambiente se dá através da ponderação dos IR_{ILN} das zonas Z1, Z2 e Z_{DPI} pelas suas respectivas áreas. O produto da IR_{ILN} do ambiente pela DPI resultará na DPU. A Tabela 5 ilustra a síntese da ponderação da IR_{ILN} .

Tabela 5 – Resultados da ponderação dos IR_{ILN} pelas respectivas áreas das zonas

	Área (m²)	IR_{ILN} (%_{DPI})
Área Total do Ambiente	34,58	
Zona 1	10,74	6,28
Zona 2	6,01	10,04
Zona DPI	17,83	100
Ponderação: IR_{ILN} ambiente		55,25

Tabela 6 – Desempenho das equações para 500 lux, PAF 80%, Zona 1 e Zona 2

ERROS INERENTES ÀS EQUAÇÕES		
	Equação Z1 500 lux PAF 80% (DA > 50%)	Equação Z1+Z2 500 lux PAF 80% (30% > D A > 50%)
r²	0,9990	0,9990
SQR	0,6504	0,6651
MAE (m²)	9,5781	12,0908

Como resultado este ambiente apresenta necessidade de uso de apenas 55,25% da DPI nas horas de ocupação. Logo, se este ambiente possuísse uma DPI de 11,90 W/m² (DPI_L do RTQ-C para classe A para escritórios), sua DPU seria 6,57 W/m².

4.2 Verificação do erro da proposta apresentada

Para a verificação dos erros inerentes à aplicação conjunta do metamodelo baseado em redes neurais artificiais com modelos de regressão exponencial, três verificações foram realizadas, como descrito no item 3.1.

A Equação 1 e a Equação 2, utilizadas no exemplo, apresentam as estatísticas exibidas na Tabela 6. No caso do exemplo, o que diferencia o modelo adotado dos modelos utilizados para gerar a equação de regressão é a refletância das superfícies. Os modelos utilizados na regressão apresentavam refletância das superfícies de 20%, 40% e 60% e de piso, parede e teto de 30%, 60% e 80%, respectivamente. O ambiente do exemplo se diferenciava do primeiro apenas pela refletância do teto, 80%.

Tabela 7 – DPU para a Zona 1 prevista pela RNA 9 e simulada pelo plug-in DIVA

J1 500 lux	Validação cruzada– RNA 9 – IR_{ILN} (%_{DPI})	Valor de IR_{ILN} simulado– IR_{ILN} (%_{DPI})
	6,28	6,78

Tabela 8 – Comparação do IR_{ILN} previsto pelo método prescritivo e simulado considerando todo o ambiente

IR_{ILN} pelo Método prescritivo	IR_{ILN} pela Simulação DIVA	Unidade
55,25	57,70	% _{DPI}
MAE pelo método prescritivo	2,45	% _{DPI}
MAPE pelo método prescritivo	4,24	% de erro

O resultado do IR_{ILN} previsto pela rede neural apresentou erro absoluto de 0,5025 IR_{ILN} (%_{DPI}) e erro percentual médio de 7,4139%. Os valores de ambos os IR_{ILN} , obtidos através da RNA 9 e da simulação computacional para a Zona 1 na simulação termoenergética no Grasshopper, são apresentados na Tabela 7.

Comparando o resultado da aplicação do método prescritivo com a simulação do ambiente todo, o erro percentual médio foi inferior a 5%, como pode ser visto na Tabela 8. O erro obtido para esse ambiente foi considerado aceitável para um método simplificado em que a velocidade na aplicação e o caráter comparativo de soluções são priorizados ante a precisão.

4.3 Impacto do aproveitamento da Iluminação Natural na classificação de eficiência energética

No trabalho de Scalco et al (2015) a redução no consumo do sistema de iluminação da proposta de *retrofit* substituindo a DPI classe D do RTQ-C pela DPI A foi de 31,21%; já para a solução com sistema LED foi de 61,70%. Comparativamente, calculou-se o consumo com iluminação artificial em kWh/m²/ano baseando-se na DPU do exemplo correspondente a 6,57 W/m², resultando em uma redução de 53,4%. A Figura 2 ilustra esta comparação para dois edifícios avaliados por Scalco et al (2015), o que apresentou menor e o que apresentou maior variação de consumo devido ao *retrofit*. Nesta figura, a barra cinza indica o resultado referente ao uso da DPU considerando que fosse aplicada a um sistema classe A do RTQ-C (DPI A + Iluminação Natural). Como pode ser observado a DPI A + Iluminação Natural apresentou diferença absoluta de 53,4% em relação à classe D e 22,2% em relação à classe A e -6,44% em relação ao LED. Em valores de consumo relativo, a opção com sistema de iluminação classe D resultou em 45,6 kWh/m²/ano, a classe A em 31,4 kWh/m²/ano, a opção com LED em 17,5 kWh/m²/ano e a DPI A + Iluminação Natural em 21,26 kWh/m²/ano.

Novamente estabelecendo um paralelo com os resultados Scalco et al (2015), quando avaliado o consumo total da edificação, em média, o *retrofit* do sistema com DPI classe D para DPI classe A possibilitou 13,3% de economia de energia enquanto que a substituição por LED 26,5%, sendo a variação entre o menor e o maior potencial de economia aproximadamente 5,5% para o primeiro caso e 11% para o segundo. A Figura 2 destaca a variação (Δ) entre o menor e o maior potencial de economia no consumo total e no sistema de condicionamento de ar e indicando a possível localização no gráfico das estatísticas de uma edificação que considerasse o aproveitamento da iluminação natural. Destaca-se que o aproveitamento da iluminação natural não apresentaria nenhum custo térmico, visto que a simulação já computa o efeito da radiação, a única diferença é que o sistema de iluminação artificial está sendo acionado com um padrão de uso menos intenso (tempo ou potência).

Quanto ao impacto na classificação da Etiqueta PBE Edifica, Scalco et al (2015) obtiveram que, para o *retrofit* utilizando a DPI classe A, 10 das 12 edificações (83%) passaram de classificação geral D para C, enquanto que nas demais a melhoria foi ainda maior, passando de D para B. Já o *retrofit* utilizando LED resultou em transferência da classe de D para A para 8 edificações (67%) e nos quatro casos restantes (33%) houve melhoria da classe D para B. Logo, diante da comparação dos desempenhos observados na Figura 2, pode-se afirmar que o aproveitamento da iluminação natural pode elevar a classe de eficiência energética de uma a três classes de eficiência energética global da edificação.

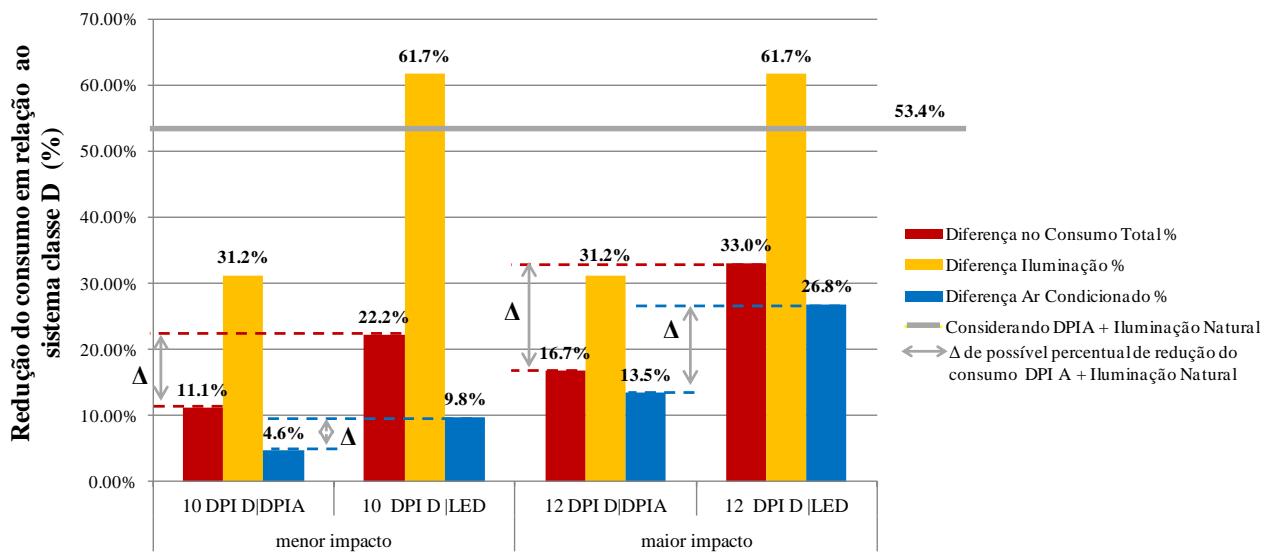


Figura 2 – Comparação da DPU do exemplo com os casos de menor e maior impacto de Scalco et al (2015).

5. CONCLUSÕES

O presente trabalho abordou uma aplicação de redes neurais artificiais como método simplificado para a previsão do impacto do aproveitamento da iluminação natural no consumo energético. O índice de iluminação natural adotado IR_{ILN} possibilita o cálculo da Densidade de Potência em Uso. Na proposta

apresentada, o IR_{ILN} foi combinado com um zoneamento de iluminação natural dinâmico para oferecer a DPU final de um ambiente.

A combinação da DPU com o zoneamento de iluminação natural dinâmico que considera diferentes iluminâncias alvo permite que projetistas utilizem as equações para espaços com diferentes usos e necessidades de iluminamento. O zoneamento ainda pode ser útil como apoio ao projeto luminotécnico para a locação de sensores de iluminação natural e a divisão dos circuitos de iluminação artificial.

Quanto à proposição da RNA baseada no IR_{ILN} , ressalta-se que, apesar de esse parâmetro ser relacionado apenas ao sistema de iluminação artificial, ele pode ser utilizado em combinação com outros métodos para gerar informação sobre o impacto no balanço térmico da edificação. Uma aplicação seria utilizar a DPU como dado de entrada para a simulação termoenergética em substituição à DPI como alternativa à simulação integrada. Isso poderia ser feito tanto em simulações detalhadas quanto em simulações simplificadas, com as várias interfaces do programa EnergyPlus, por exemplo. Além de dado de entrada para a simulação computacional, pode servir como dado de entrada para outros métodos simplificados destinados à previsão do desempenho térmico da edificação que considerem a influência da densidade de potência instalada de iluminação.

Outra possível aplicação seria para complementar o Regulamento Técnico da Qualidade de Edificações Comerciais, de Serviços e Públicas (RTQ-C) (INMETRO, 2010), aplicando a ponderação de áreas de DPU e DPI para computar o aproveitamento da luz natural junto ao termo referente à avaliação do sistema de iluminação artificial, da Equação da Pontuação Final do mesmo regulamento ver Equação 4.

$$PT = 0,30 * \left\{ \left(EqNumEny * \frac{AC}{AU} \right) + \left(\frac{APT}{AU} * 5 + \frac{ANC}{AU} * EqNumV \right) \right\} + 0,30 * (EqNumDPI) + 0,4 * \left\{ \left(EqNumAC * \frac{AC}{AU} \right) + \left(\frac{APT}{AU} * 5 + \frac{ANC}{AU} * EqNumV \right) \right\} + b_0^1 \quad (4)$$

Assim, utilizando-se a abordagem apresentada, de considerar a DPU do ambiente em vez da DPI, projetos que priorizem a iluminação natural poderiam ser mais bem valorizados. No procedimento de determinação da eficiência, através da DPU obtida, calcular-se-ia a Potência em Uso, sendo essa utilizada para obter a classificação do nível de eficiência através da comparação com as Densidades de Potência Limite (DPI_L), conforme as Tabelas 4.1 e 4.2 do RTQ-C (INMETRO, 2010). A utilização da DPU pode ser condicionada ao uso de controles de iluminação artificial. A locação desses controles poderia ser vinculada ao zoneamento de iluminação natural (Zona 1 e Zona 2). Para diferentes tipos de controle, fatores de ajustes poderiam ser propostos. Ambientes que não dispusessem de sistemas de controle seriam avaliados da forma vigente no regulamento. A ponderação dar-se-ia da mesma forma; entretanto, em vez de considerar somente a Potência Instalada, os ambientes que aproveitam a iluminação natural poderiam utilizar a Potência em Uso. Por fim, a abreviação de Equivalente Numérico de Iluminação – $EqNumDPI$ poderia ser mais adequadamente adaptada para $EqNumIL$.

A rede neural adotada pode ser melhorada através do ajuste adequado do número de neurônios na camada interna e da ampliação do número de casos na amostragem. Dessa forma, pode-se melhorar a sua confiabilidade para a previsão de casos nunca antes apresentados para a RNA. Por fim, o exemplo de aplicação foi feito apenas para a cidade de Florianópolis, para outras localidades, tanto o zoneamento quanto a rede neural devem ser replicados.

A comparação dos resultados do exemplo apresentado com os resultados Scalco et al (2015) permitiram confirmar o elevado impacto energético que o aproveitamento da iluminação natural pode gerar. Apesar do sistema DPI A + Iluminação Natural não ter apresentado economia superior ao sistema LED, vale destacar que o ambiente do exemplo não se trata de um espaço projetado a fim de maximizar o aproveitamento da iluminação natural. Além disso, a iluminação natural apresenta inúmeros outros benefícios como o melhor índice de reprodução de cor (IRC), a relação com os aspectos biológicos e com a saúde humana, a relação com a produtividade e bem estar do usuário que não pode ser obtidos através de nenhuma fonte de iluminação artificial. Estes aspectos podem ser relacionados direta ou indiretamente com a eficiência energética, a exemplo dos IRCs, que segundo Papamichael et al. (2015), quando elevados, podem compensar a necessidade de altos níveis de iluminância e, como resultado, reduzir consumo de energia. Assim, um projeto de qualidade que considere a iluminação artificial integrada à iluminação natural pode se beneficiar duplamente, em termos energéticos, primeiro reduzindo os níveis necessários de iluminância e depois reduzindo o uso do sistema de iluminação artificial.

REFERÊNCIAS BIBLIOGRÁFICAS

- ASHRAE Standard 90.1 - Energy Standard for Buildings Except Low-Rise Residential Buildings **American Society of Heating Refrigeration and Air-Conditioning Engineers.** 90.1.Atlanta, 2013.
- ASSAF, L. O.; PEREIRA, F. O. R. **Perspectivas de la eficiencia energética en la iluminación: desafios para el desarrollo.** VII ENCAC - Encontro Nacional sobre Conforto no Ambiente Construído e III COTEDI - Conferência Latino Americana sobre Conforto e Desempenho Energético nas Edificações. Curtiba, 2003.
- 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.
- CALIFORNIA ENERGY COMMISSION. TITLE 24 - 2013 Building Energy Efficiency Standards for Residential and Nonresidential Buildings CEC-400-2012-004-CMF-REV2. California Energy Comission.Part 1. Number 252, 2013.
- CIE. TC 6-11. Draft "Ocular Lighting Effects on Human Physiology, Mood and Behaviour". **Commission Internationale d'Eclairage**, 2003.
- EPBD-NCM. **National Calculation Methodology (NMC) modelling guide (for buildings other than dwellings in England):** Department for Communities and Local Government: 2014, 55 p.
- FELIPPE, A. R., et al. **Parametric Modeling of Daylighting and Energy Consumption with an Integration of Simulation Tools.** In: 14th International Conference of the International Building Performance Simulation Association Hyderabad IBPSA. 7 a 9 de dezembro, 2015. No prelo.
- FONSECA, 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.
- FONSECA, R. W. Iluminação natural e consumo energético de edificações não residenciais: as possibilidades e as limitações da aplicação de redes neurais artificiais. (tese de doutorado) Departamento de Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2015. 350 p. No prelo.
- HAYKIN, S. **Redes Neurais: Princípios e Práticas.** 2:Porto Alegre: ARTMED Editora S.A. 200, 900 p.
- INMETRO. Requisito técnico da qualidade para o nível de eficiência energética de edifícios comerciais, de serviços e públicos. **Ministério do Desenvolvimento.** Portaria n. 372. INMETRO, 2010.
- KALOGIROU, S. A. Artificial neural networks in renewable energy systems applications: a review. **Renewable and Sustainable Energy Reviews**, v.5, n.4, p.373-401, 2001.
- KRARTI, M. An Overview of Artificial Intelligence-Based Methods for Building Energy Systems. **Journal of Solar Energy Engineering**, v.125, n.3, Agosto 2003, 2003, p.331-342.
- MAYHOUB, M. S. e CARTER, D. J. Towards hybrid lighting systems: A review. **Lighting Research & Technology**, v.42, n.1, p.51-71, 2010.
- PAPAMICHAEL, K.; SIMINOVITCH, M.; VEITCH, J. A.; WHITEHEAD, L. High Color Rendering Can Enable Better Vision without Requiring More Power. **Leukos**, March 2015, p. 1–12.
- PEREIRA, F. O. R., et al. **An Investigation about the Consideration of Daylighting along the Design Stages.** In: Passive and Low Energy Architecture - PLEA, 2005: Environmental Sustainability - The Challenge of Awareness in Developing Societies. Beirute, 2005, 1025-1030 p.
- SCALCO, V. A.; BECK, E. L.; FONSECA, R. W.; IMPROTA, M.; LAMBERTS, R. Retrofit do Sistema de Iluminação em Edificações de Escritórios: Potencial de economia de energia de acordo com método da Etiqueta PBE Edifica. **Lumiere Eletrics**, maio de 2015, p.13.
- WILLIAMS, A., et al. Lighting Controls in Commercial Buildings. **LEUKOS - Journal of Illuminating Engineering Society of North America**, v.8, n.3, 2012, p.161 a 180.
- WONG, S. L., WAN, K. K. W. e LAM, T. N. T. Artificial neural networks for energy analysis of office buildings with daylighting. **Applied Energy**, v.87, n.2, 2010, p.551-557.
- ZHAO, H.-X.; MAGOULÈS, F. A review on the prediction of building energy consumption. **Renewable and Sustainable Energy Reviews**, v.16, n.6, 2012, p.3586-3592.

AGRADECIMENTOS

Os autores agradecem o apoio financeiro da CAPES, CNPQ e da Eletrobras no âmbito do Convênio ECV-DTP 002/2011 celebrado entre a Eletrobras e UFMG/UFSC.