

## Redes neurais artificiais para estimar a iluminação natural em ambientes residenciais com obstrução do entorno

### Artificial neural networks to estimate daylighting in dwellings with neighborhood obstruction

<sup>1</sup>Raphaela Walger da Fonseca, <sup>2</sup>Pedro Oscar Pizzetti Mariano, <sup>3</sup>Fernando Oscar Ruttkay Pereira

<sup>1</sup>Arquiteta e Urbanista, Doutora em Engenharia Civil – Universidade Federal de Santa Catarina (raphaela.walger@ufsc.br)

<sup>2</sup>Doutorando do Programa de Pós-graduação em Arquitetura e Urbanismo — Universidade Federal de Santa Catarina (pedro.pm@hotmail.com)

<sup>3</sup>Professor Titular do Programa de Pós-graduação em Arquitetura e Urbanismo – Universidade Federal de Santa Catarina (ruttkay.pereira@ufsc.br)

**RESUMO:** Muitos países adotam instrumentos regulatórios para a melhoria do desempenho das edificações e a qualidade luminosa é frequentemente abordada em seus escopos. Métodos simplificados facilitam a aplicação de tais instrumentos e a inteligência artificial tem se mostrado útil para esse fim. Assim, o objetivo deste trabalho é a propor um metamodelo, utilizando-se redes neurais artificiais, para verificar o desempenho luminoso de edificações residenciais, considerando o impacto do entorno construído no contexto da revisão da norma brasileira “ABNT NBR 15.575-1 Edificações habitacionais — Desempenho”. Para isto, adotou-se a base de dados simulados para a proposta de revisão da norma, contendo 36.000 casos que relacionam a influência de obstruções externas à edificação ao seu desempenho quanto à suficiência e uniformidade da luz natural. Assim, metamodelos de redes neurais artificiais Perceptron Multicamadas foram treinados com dados das cidades de Curitiba, Brasília e Belém. A arquitetura das redes consistiu em 3 camadas, a de entrada, uma oculta e a de saída. Testaram-se aspectos de sua arquitetura e do agrupamento dos parâmetros de entrada, as variáveis da edificação, e de saída,  $ALNE_{200lx,50\%}$  e  $ALNE_{60lx,50\%}$ . O seu desempenho global foi considerado aceitável, com erro percentual médio inferior a 10%, sendo necessário o seu refinamento para a redução de discrepantes. Concluiu-se que as RNA podem ser uma alternativa como método simplificado para aplicação na norma, apontando-se como opções de refinamento do metamodelo a variação do algoritmo de aprendizagem, da partição dos conjuntos de treinamento e teste, e a ampliação do seu escopo com outras proporções e transmissões visíveis.

**Palavras Chave:** Redes neurais artificiais. Iluminação natural. Desempenho de edificações. Obstruções do entorno.

**ABSTRACT:** Many countries adopt regulatory instruments to improve buildings' performance and daylighting quality is often addressed in their scopes. Simplified methods facilitate the application of such instruments and artificial intelligence has been shown to be useful for this purpose. Thus, the aim of this work is to propose a metamodel, using artificial neural networks, to verify the dwellings daylighting performance, considering the surroundings impact, in the context of the Brazilian standard "ABNT NBR 15.575-1 Residential Buildings — Performance" revision process. For this, the simulated database for the standard revision, containing 36,000 cases that relate the influence of external obstructions to the building to its performance regarding the sufficiency and uniformity of natural light was adopted. Thus, Multilayer Perceptron artificial neural network metamodels' were trained with data from the cities of Curitiba, Brasília and Belém. The networks' architecture consisted of 3 layers, the input, a hidden and the output. Aspects of them architecture and the grouping of input parameters, building variables, and output parameters,  $sDA_{200lx,50\%}$  and  $sDA_{60lx,50\%}$ , were evaluated. Its global performance was considered acceptable, with a mean percentage error of less than 10%, requiring its refinement to reduce outliers. It was concluded that ANN can be an alternative as a simplified method for application in the standard, pointing out as options for refining the metamodel the variation of the learning algorithm, the partition of the training and test sets, and the expansion of its scope with other proportions and visible transmissions.

**Keywords:** Artificial neural networks. Daylighting. Building performance. External obstructions.

## 1. INTRODUÇÃO

Muitos países adotam códigos, normas e certificações com o objetivo de melhorar o desempenho de suas edificações. A qualidade luminosa, bem como a sua influência no desempenho energético dos edifícios, usualmente faz parte dessas avaliações. Nesse contexto, está vigente no país a Portaria INMETRO n.º 309/2022 (INMETRO, 2022), com seus anexos *I — Instrução normativa INMETRO para a eficiência energética das edificações comerciais, de serviços e públicas* e *II — Instrução normativa INMETRO para a eficiência energética das edificações residenciais* visando classificar o consumo de energia elétrica nas edificações. Essa normativa contabiliza os benefícios do aproveitamento da iluminação natural, ainda que superficialmente.

Já sob o aspecto qualitativo, foi publicada em 2021 a norma brasileira ABNT NBR 15575-1 Edificações habitacionais — Desempenho (ABNT, 2021). Essa norma apresenta, entre outros, requisitos mínimos para a garantia da qualidade do ambiente luminoso. Entretanto, a sua principal limitação é que o seu método contempla a iluminação natural de forma estática e pontual, desconsiderando a variação do clima ao longo do ano e a distribuição da luz no ambiente (PEREIRA, FONSECA e SCALCO, 2017).

A avaliação do desempenho luminoso de edificações residenciais e comerciais difere no padrão de uso dessas edificações, da operação dos sistemas de iluminação e dos dispositivos de controle de iluminação excessiva proveniente das aberturas. Na maior parte dos casos, as edificações comerciais apresentam o pico de ocupação durante o dia, enquanto nas residências, o pico de ocupação ocorre no início e no final do dia (QUEIROZ, 2011). Entretanto, com o aumento da flexibilidade de local de trabalho, existe um número crescente de pessoas trabalhando em casa, ou cumprindo parte de sua jornada de trabalho em ambientes residenciais (CIN, 2017, GONSALVES, 2020). Essa condição foi reforçada depois do isolamento social decorrente da pandemia COVID-19 (PACINI, TOBLER e BITTENCOURT, 2023).

Quanto ao padrão de uso do sistema de iluminação, em ambientes corporativos é mais frequente o uso de dispositivos de controle, como sensores de luz natural. Já em ambientes residenciais, o acionamento se dá manualmente pelo usuário. Quanto ao controle de iluminação excessiva em edificações residenciais, não há um padrão comportamental consagrado, dependendo da atividade que está sendo realizada, bem como de aspectos subjetivos ou de ordem pessoal. Por outro lado, em edificações comerciais, a iluminação em excesso é preferencialmente evitada (REINHART, 2004).

A indicação do potencial luminoso da edificação, oferecendo informações quanto a suficiência de luz natural, pode ser útil tanto para edificações comerciais, quanto residenciais. Tal informação, tem aplicação sob o enfoque energético e de aspectos qualitativos de análise das edificações, possibilitando avaliações e melhorias ainda durante o desenvolvimento do projeto. Investigações como a de Pereira et al. (2005) apontam a própria solução de projeto como uma das causas da não utilização de recursos ambientais renováveis e gratuitos nos ambientes internos, como a luz natural. Os profissionais em sua grande maioria, ainda que considerem importante o aproveitamento dos recursos naturais, não utilizam métodos e práticas que efetivamente conduzam a um aproveitamento dos recursos regenerativos no projeto arquitetônico, por vezes, devido à deficiência na apropriação das ferramentas de apoio ao projeto (GALAFASSI, 2012).

Nesse viés, ferramentas computacionais são utilizadas para a modelagem do desempenho luminoso e/ ou energético de edificações, tanto por meio de simulação

computacional (SOLEMA, 2022; LADYBUG TOOLS, 2022), quanto de ferramentas simplificadas de auxílio ao projetista (MARSH, 2023; VELUX, 2023). Contudo, as simulações computacionais demandam elevado detalhamento e profissionais devidamente treinados para garantir a qualidade dos resultados. Assim, métodos simplificados são importantes ferramentas para serem utilizadas, em especial, nas fases iniciais de projeto, em que as principais decisões estão sendo tomadas. Em contraste com a simulação computacional, propiciam respostas rápidas sem necessitar de significativo detalhamento de informações. Embora exista uma grande quantidade de métodos simplificados, poucos possibilitam a avaliação do impacto da iluminação natural, considerando a avaliação espacial, o dinamismo do clima, da orientação, bem como do entorno, fundamentais para a avaliação de desempenho luminoso da edificação (FONSECA, 2015).

As redes neurais artificiais (RNAs) são utilizadas com boa resposta para modelagens em várias áreas de pesquisa (ROMAN et al., 2020; LU, LI e LU, 2022) indicando elevado potencial para a modelagem do desempenho de edifícios quanto à iluminação natural (NGARAMBE et al., 2022; FONSECA e PEREIRA, 2021; LORENZ, et al., 2019). As RNAs tratam-se de técnicas computacionais de abordagem não linear, baseadas em modelos computacionais que utilizam inteligência artificial e que, assim como os demais modelos, objetivam representar ou aproximar sistemas (HAYKIN, 2001; SILVA et al., 2004).

Diante do exposto, o objetivo deste trabalho é a propor um metamodelo, utilizando-se redes neurais artificiais, para verificar o desempenho luminoso de edificações residenciais, considerando o impacto do entorno construído no contexto da revisão da norma brasileira ABNT NBR 15.575-1 Edificações habitacionais — Desempenho (ABNT, 2021). Para isso, adotaram-se as cidades de Curitiba, Brasília e Belém como estudos de caso.

## 2. CONCEITUAÇÃO

As redes neurais artificiais (RNAs) 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. Essas técnicas buscam reproduzir o comportamento e a dinâmica do cérebro, adquirindo conhecimento através da experiência (SILVA et al., 2004). As RNAs têm por objetivo fornecer subsídios para a ferramenta computacional conseguir, baseada em um conjunto de simulações conhecidas, estender tais informações para determinada situação proposta (COSTA, 2001).

A habilidade de aprender é uma das principais propriedades de uma rede neural. Haykin (2001) define aprendizagem como:

[...] um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre. (HAYKIN, 2001, p. 75).

A modificação dos parâmetros referida por Haykin (2001) traduz-se no ajuste dos pesos sinápticos, visto que uma rede com pesos sinápticos adequados pode representar praticamente qualquer função. Logo, a aprendizagem consiste no processo de encontrar os pesos adequados. Para tal, inicia-se o processo adotando-se pesos arbitrários e, interativamente, aplicando um algoritmo de aprendizagem, esses pesos são ajustados; assim, a rede pode chegar ao desempenho desejado.

Em outras palavras, o treinamento de uma rede neural tem por objetivo produzir um conjunto de saídas desejadas ou mesmo consistentes através da aplicação de determinado

conjunto de entradas. Cada um desses conjuntos (de entrada ou saída) denomina-se vetor. Realiza-se o treinamento através da aplicação sequencial de vetores de entrada e, algumas vezes, também os de saída, enquanto se ajustam os pesos da rede conforme um procedimento de treinamento escolhido previamente. Durante o processo de treinamento, os pesos vão gradualmente convergindo para determinados valores, até que os vetores de entrada produzam as saídas desejadas (BOCANEGRA, 2002). Para melhorar o aprendizado da rede, a escolha do conjunto de treinamento deve considerar valores extremos, visto que as RNAs apresentam elevado poder de interpolação, mas limitações quanto à extrapolação.

### 3. MATERIAIS E MÉTODO

Visando compatibilizar o estudo com a revisão da norma ABNT NBR 15.575-1 Edificações habitacionais — Desempenho (ABNT, 2021), as redes neurais foram treinadas com a mesma base de dados utilizada para a proposta elaborada pela equipe do Laboratório de Conforto Ambiental da Universidade Federal de Santa Catarina para os Ábacos do método simplificado (MARIANO; et al., 2020, PEREIRA; et al., 2020, GIRALDO; et al., 2021). Assim, o requisito abordado é a provisão de luz natural avaliada com base em dois critérios: i) Suficiência (iluminância alvo) e ii) Uniformidade (iluminância mínima), a serem atendidos simultaneamente. Ambos os critérios adotam o conceito de Autonomia da Luz Natural, cujas iluminâncias alvo são 200 lux e de 60lux, respectivamente, que precisam ser alcançados em 50% do período de ocupação, em determinada fração da área do ambiente interno. Logo, os parâmetros de saída das redes neurais foram valores de Autonomia da luz Natural Espacial — ALNE, tendo como alvo as duas iluminâncias,  $ALNE_{200lx,50\%}$  e  $ALNE_{60lx,50\%}$ . Assim, primeiramente a base de dados será apresentada e analisada e então, será apresentado o método do treinamento das redes.

#### 3.1 A base de dados para treinamento

Os modelos paramétricos que compõem a base são representativos de tipologias arquitetônicas residenciais difundidas na indústria da construção civil brasileira com predominância de ambientes retangulares (PONTUAL, 2009; ANDRADE e CHENG, 2006). A base foi gerada por simulações computacionais de Autonomia da luz Natural Espacial com arquivos climáticos TMYx 2003 – 2017 (CRAWLEY e LAWEIE, 2018), conforme recomendado por Fonseca (2018). As cidades contempladas na base de dados são Belém [Latitude 1°27'20" S e Longitude 48°30'15" O], Brasília [Latitude: 15°46'46" S e Longitude: 47°55'46" O] e Curitiba [Latitude: 25°25'40" S e Longitude: 49°16'23" O]. As cidades referem-se às três faixas de latitude propostas por Fonseca (2018) com variação máxima de 3.º entre a longitude das cidades.

A base é composta por 36.000 casos resultantes das combinações paramétricas entre as variáveis da

Tabela 1. A geometria do ambiente foi abordada segundo conceito de tamanho e proporção, baseando-se em geometria retangular (Figura 1). O tamanho foi associado à largura dos ambientes e a proporção à relação entre largura e profundidade. Foram adotadas 5 larguras diferentes e 4 relações de proporção com a profundidade do ambiente (Tabela 1).

A área da abertura foi fixada em 1/6 da área do piso, correspondente ao critério de abertura mínima para quartos e salas, adotado por grande parte dos códigos de obras brasileiros (PEREIRA, SCHIMITT e MORAES, 2015). Essa simplificação permite a

avaliação da condição mais restritiva para iluminação natural, associada a menor abertura permitida por muitos códigos de obra para esses ambientes. Tal premissa vai de encontro com o objetivo da norma de garantir um desempenho mínimo para as edificações.

Tabela 1 – Variáveis paramétricas

Parâmetros	Valores			
<b>Ambiente</b>				
Pé-direito	2,7 m			
Altura da verga (h)	2,1 m			
Largura (l)	Combinadas parametricamente com as 4 relações de profundidade: 1,5 m; 3 m; 4,5 m.		Extras: 2,25 m * (4 profs. abaixo + 1*3); 3,75 m * (apenas 1*1); 2 m * (apenas 1*3 e 1*3,5).	
Profundidade	1*1; 1*1,5; 1*2; 1*2,5			
Refletância das superfícies	Piso: 20%; Parede: 50%; Teto: 80%			
Orientação	Norte	Leste	Sul	Oeste
<b>Abertura</b>				
Área	1/6 da área do piso			
Transmissão visível do vidro	88%	60%	40%	
Localização da abertura	Centro do ambiente			
Peitoril janela	inexistente		existente	
<b>Sacada</b>				
Condição	inexistente		existente	
Profundidade	—		1,5 m	3 m
Peitoril da sacada	existente			
Refletância superfícies	Piso: 20%; Parede: 50%; Teto: 80%			
<b>Entorno Urbano</b>				
Ângulos de Obstrução do entorno	20%; 30%; 40%; 45%; 55%; 60%; 65% 70%; 80%			
Refletância do entorno	Piso externo: 10%		Edificações: 35%	

De maneira a limitar a quantidade de combinações paramétricas, o pé-direito e a altura da verga da janela foram mantidos fixos, assumindo-se que as tipologias residenciais apresentam pouca variação desses elementos. As refletâncias também foram fixadas com valores de referência propostos pela Illuminating Engineering Society (2012), conforme apresentado na Tabela 1, visto que imóveis normalmente são entregues com acabamento padrão. As obstruções do entorno foram consideradas de maneira simplificada, como sendo uniformes e contínuas (Figura 1).

A parametrização e as simulações foram realizadas no conjunto de programas, Rhinoceros, Grasshopper e DIVA-for-Rhino (MCNEEL, 2019; SOLEMA, 2020). Mais informações sobre o algoritmo de parametrização podem ser obtidas em Mariano *et al.* (2020). A malha de pontos foi espaçada em 0,3 m. O período de ocupação foi considerado das 8h às 18h, em todos os dias do ano. Os parâmetros de simulação adotados são apresentados na

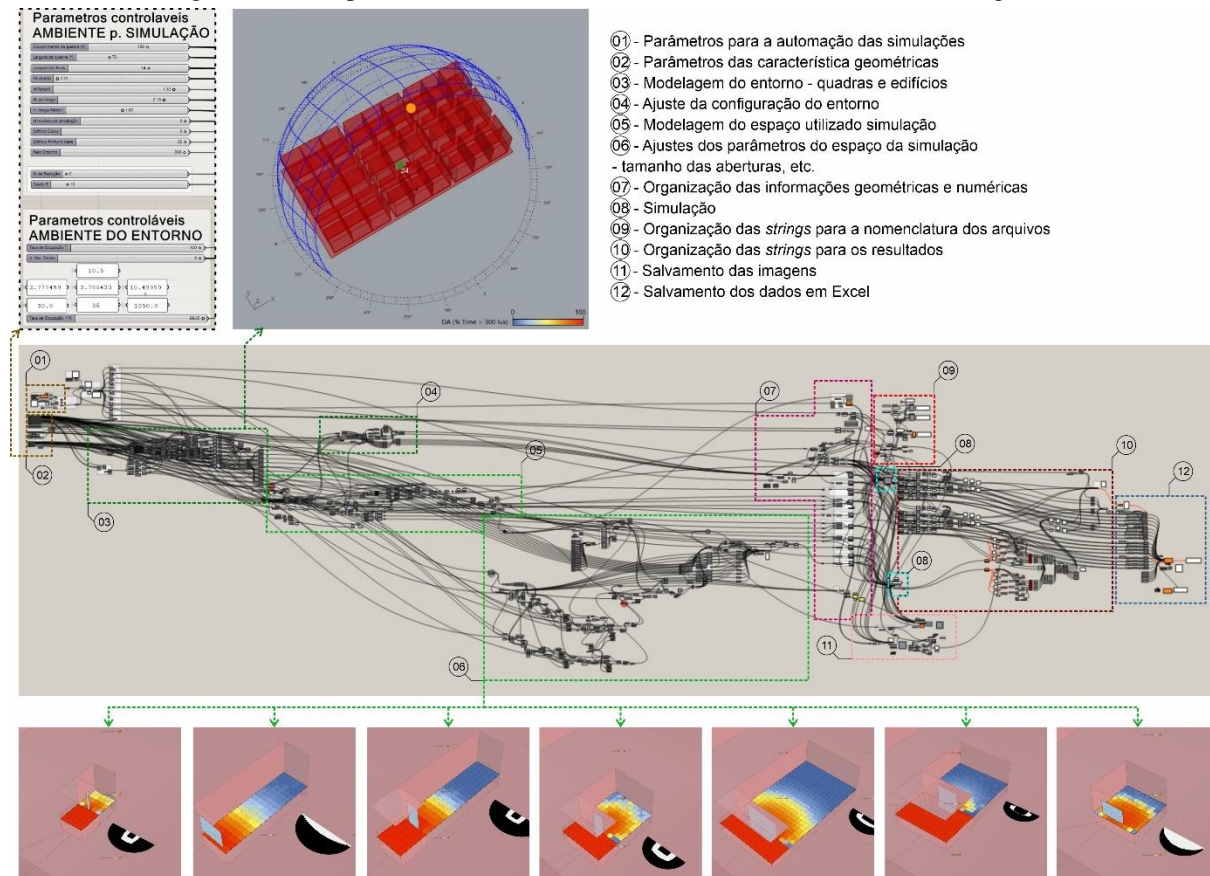
Tabela 2.

Tabela 2 – Parâmetros do Radiance adotados para a simulação realizada pelo algoritmo de parametrização

Inter reflexões do ambiente	Divisão do ambiente	Amostragem do ambiente	Precisão do ambiente	Resolução do ambiente	Limiar direto	Amostragem direta
5	1024	256	0,1	256	0	0

A análise estatística descritiva dos dados simulados para a proposição do metamodelo foi feita no programa livre GNU PSPP (FSF, 2016) e em planilha Excel (MICROSOFT, 2020). Todas as variáveis foram avaliadas, sendo as nominais descritas por meio de frequências e as numerais por meio das medidas: mediana, máximo, mínimo, skewness, erro padrão do skewness, curtose, erro padrão da curtose, intervalo, variância, desvio padrão, moda, média e erro padrão da média. Todas as variáveis dependentes foram avaliadas por meio de histogramas de frequência, incluindo a sobreposição da curva normal.

Figura 1 – Exemplo de ambiente e modelo do entorno urbano em formato de grelha



### 3.2 Proposta da RNA

O treinamento das redes neurais artificiais foi feito no programa MATLAB (MATHWORKS, 2020). As redes neurais são do tipo *Perceptron* Multicamadas alimentadas à diante, com processo de aprendizagem supervisionada, aplicando a retropropagação do erro. O algoritmo adotado foi a Regularização Bayesiana. Adotou-se o treinamento múltiplo, sendo

treinadas diversas redes para cada avaliação. A análise do tamanho da camada oculta baseou-se no treinamento múltiplo de 10 RNAs e as demais análises de 5 RNAs.

Quanto à arquitetura, todas as redes avaliadas possuem 3 camadas: a de entrada, uma camada oculta e a de saída. Os parâmetros de entrada corresponderam aos parâmetros de descrição do ambiente interno e do entorno indicados na

Tabela 1; e os parâmetros de saída, à área do ambiente que atende a  $ALNE_{200lx,50\%}$  e  $ALNE_{60lx,50\%}$ .

A proposição dos metamodelos foi feita sistematicamente. As redes foram avaliadas quanto ao seu potencial para estimar a autonomia da luz natural espacial para novas configurações geométricas, resultantes da variação de tamanho e proporção. O desempenho das redes foi avaliado por meio de análise de erros utilizando-se o MAPE — erro absoluto percentual médio, o MAE — erro absoluto médio e o RMSE — raiz do erro quadrático médio. Julgou-se válido diferenciar as unidades das medidas de erro adotadas: para o MAPE o símbolo de % refere-se ao erro percentual de qualquer métrica avaliada; já o símbolo % utilizado para o erro absoluto (MAE) e à raiz do erro quadrático médio (RMSE) refere-se ao percentual da área do ambiente que atinge os alvos de ALNE, a unidade desta métrica.

A primeira avaliação visou definir as variáveis necessárias à camada de entrada da rede para descrever a configuração espacial dos ambientes. Para essa etapa, considerou-se apenas a cidade de Curitiba e a transmissão visível de 80%. Isso, porque em estudo anterior Pereira, et.al. (2020) comprovaram haver diferença estatística entre os conjuntos de dados com as diferentes transmissões visíveis, o que levou ao grupo do LabCon a fazer Ábacos independentes para a proposta da norma.

O conjunto de treinamento correspondeu às larguras de 1,5 m; 3 m; 4,5 m, combinadas com as 4 relações de profundidade, resultantes das proporções geométricas 1:1; 1:1,5; 1:2; 1:2,5 (


Tabela 1 e



Figura 2). O conjunto de teste correspondeu às larguras extras de 2,25 m e 3,75 m, respeitando as relações apresentadas na

Tabela 1. A Figura 2 ilustra a projeção horizontal dos ambientes, sendo a sua largura representada no eixo x, a profundidade no eixo y e a proporção na diagonal. As demais variáveis foram combinadas parametricamente utilizando os valores apresentados na mesma tabela. Assim, as redes foram treinadas com 2.800 casos e testadas com 1.200.

Figura 2 – Projeção horizontal representativa das larguras e proporções distribuídas nos conjuntos de treinamento e teste



**Legenda:**

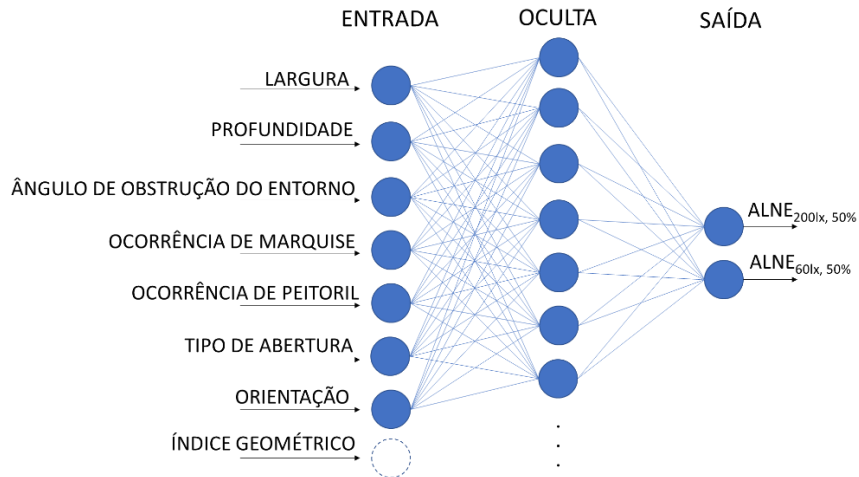
- |                             |  |   |
|-----------------------------|--|---|
| L1: largura 1 igual a 1,5 m | Lnv1: largura extra 1 nunca vista pela RNA antes do teste igual a 2,25 m | p1:1: proporção 1:1 entre largura e profundidade do ambiente      |
| L2: largura 2 igual a 3 m   | Lnv2: largura extra 2 nunca vista pela RNA antes do teste igual a 3,75 m | p 1:1,5: proporção 1:1,5 entre largura e profundidade do ambiente |
| L3: largura 3 igual a 4,5 m |  | p 1:2,5: proporção 1:2,5 entre largura e profundidade do ambiente |

Nesta primeira etapa, foi avaliado o tamanho da camada oculta e a necessidade de um índice geométrico para o aprendizado das redes. A

Figura 3 ilustra a arquitetura base das redes. As redes para a avaliação da quantidade de neurônios ocultos compuseram-se de 8 neurônios de entrada, conforme as variáveis do ambiente parametrizadas apresentadas na

Tabela 1: largura, profundidade, ângulo de obstrução, ocorrência de sacada, ocorrência de marquise, ocorrência de peitoril, tipo de abertura (porta ou janela) e orientação. A camada de saída foi mantida com os 2 parâmetros de autonomia da luz natural já mencionados,  $ALNE_{60lux,50\%}$  e  $ALNE_{200lx,50\%}$ . A camada oculta foi testada com 4, 5, 12, 17 e 28 neurônios, cujo tamanho resultou da aplicação de diversas heurísticas. As quantidades de 4 e de 5 neurônios originaram-se respectivamente de recomendações do NCE da UFRJ (NCE, 2020), sugerindo a média aritmética ou geométrica resultante da relação entre o tamanho das camadas de entrada e saída da rede. A camada com 12 neurônios correspondeu à aplicação de uma heurística comumente encontrada em fóruns de discussão sobre o assunto, que indica que a quantidade seja de 1,5 vezes o tamanho da camada de entrada. As quantidades de 17 e 28 neurônios resultaram da aplicação das heurísticas de Hecht-Nielsen (1987) e de Upadhyaya-Eryurek (1992), respectivamente.

Figura 3 – Arquitetura base das redes




A necessidade de um índice geométrico foi testada a partir dos resultados do tamanho da camada oculta. A melhor configuração de rede da etapa anterior foi então adotada como referência, e chamada rede sem índice geométrico. O seu desempenho foi comparado ao de 3 novas configurações, resultantes da adição de um índice geométrico, somando um parâmetro na camada de entrada. Foram testados o índice P (Equação 1), o índice K (Equação 2) e o índice RCR (Equação 3), conforme os valores apresentados na Figura 4. O método que resultou na quantidade de neurônios da rede de melhor desempenho na etapa anterior, o Upadhyaya-Eryurek (1992), foi replicado para a definição do tamanho da camada oculta das redes com índice geométrico. Assim, as redes consistiram em uma camada de entrada com 9 neurônios, uma camada oculta com 31 e a camada de saída permaneceu inalterada, com 2 parâmetros. Após decidido o índice geométrico, as redes ainda foram avaliadas quanto à pertinência de serem individualizadas por parâmetro de saída.

$$\text{Índice } P = \text{Largura} / \text{Profundidade} \quad \text{Eq. 1}$$

$$K = (\text{Profundidade} \times \text{Largura}) / [(\text{Profundidade} + \text{Largura}) \times \text{Altura}] \quad \text{Eq. 2}$$

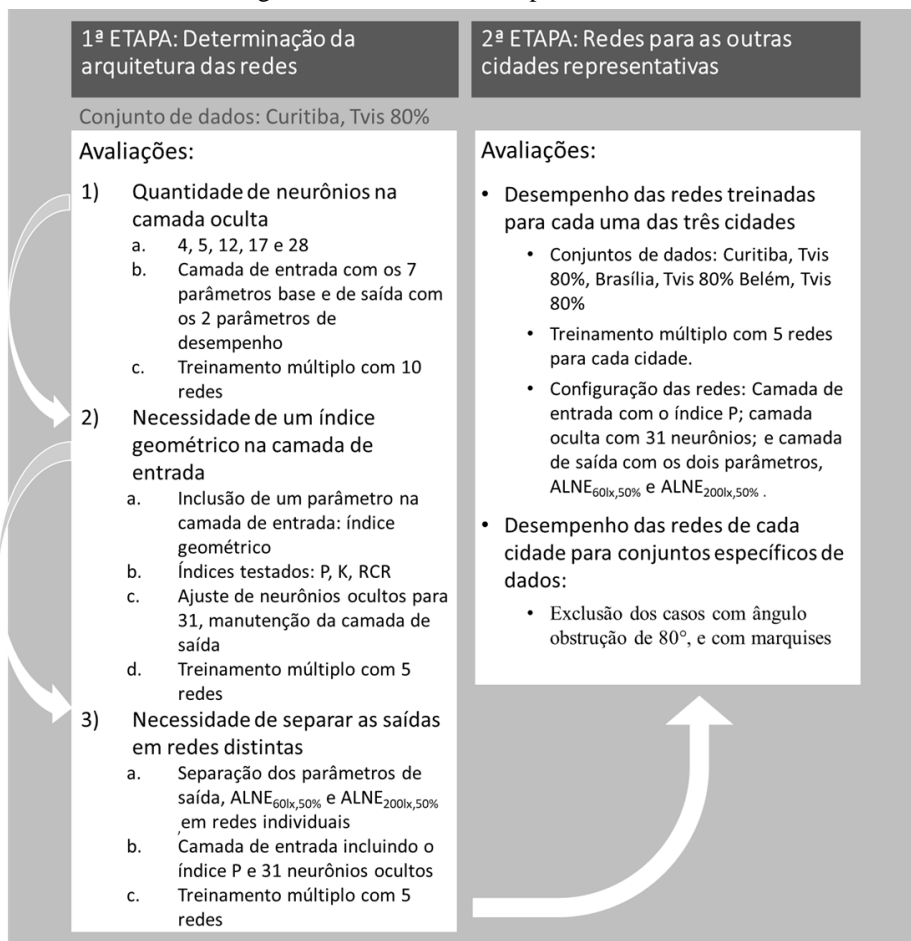
$$RCR = [5 \times \text{Altura} \times (\text{Profundidade} + \text{Largura})] / (\text{Profundidade} \times \text{Largura}) \quad \text{Eq. 3}$$

Figura 4 – Variação numérica dos índices geométricos presentes na base de dados



Na segunda etapa, a melhor configuração obtida para Curitiba, quanto ao tamanho da camada oculta, à necessidade de um índice geométrico e da individualização ou não dos parâmetros de saída em redes distintas, foi replicada para Brasília e Belém. Os resultados foram avaliados individual e comparativamente. Posteriormente, a análise foi repetida, excluindo-se os resultados dos casos com obstrução de 80.º e os com marquise, visando aprofundar a análise dos discrepantes. A

Figura 5 – Resumos das etapas do método



## 4. RESULTADOS

### 4.1 Análise estatística da base de dados

A seguir serão apresentados os resultados das estatísticas descritivas, sintetizados na Tabela 3. Os resultados foram separados em dois grupos, o primeiro em que a contabilização da área válida para a ALNE inclui a área de sacadas anexas ao ambiente e a segunda, em que a área da sacada não é integrada. Tal avaliação foi feita, uma vez que na proposta para a norma ABNT NBR 15.575 a área da sacada foi incorporada ao ambiente anexo a ela por meio de um novo conceito de ambiente luminoso. Esse conceito considera que a fonte de luz é a extremidade da sacada e que usualmente esses espaços acabam tendo o seu uso agregado ao

do ambiente que dá acesso à sacada. Para diferenciar as variáveis pertencentes ao grupo que integra a área da sacada das variáveis do grupo que não integra, foi incluída a sigla SS (sem sacada) às variáveis do último grupo.

Nota-se que a moda, o valor que mais ocorre no conjunto de dados vai de um extremo a outro, de ALNE igual a 0% da área para 200 lux à 100% da área para 60 lux, não havendo valores intermediários tanto para o conjunto que incorpora a área da sacada, como para o conjunto que não incorpora a área da sacada. Para todos os casos, a moda se distanciou significativamente da média e da mediana, indicando conjuntos de distribuição assimétrica. Já os valores da média e da mediana foram próximos entre si, sendo a maior variação observada para SS\_ALNE<sub>200lx,50%</sub> (sem a incorporação da sacada).

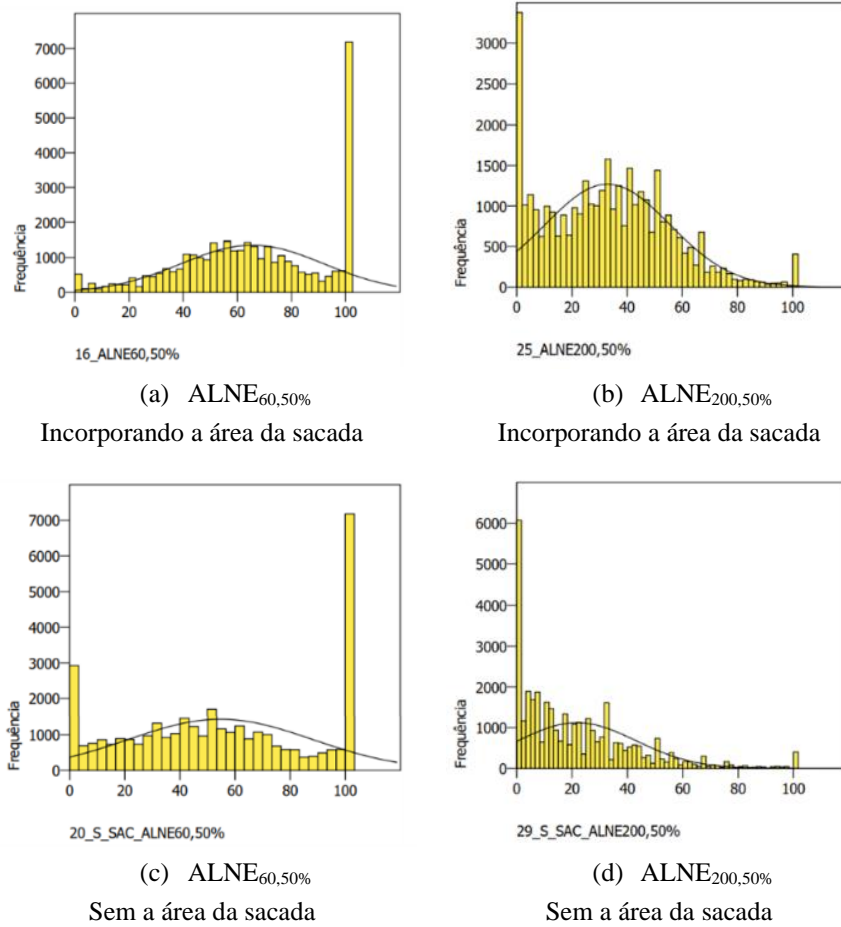
Tabela 3 – Medidas estatísticas para as variáveis dependentes

	ALNE <sub>60lx,50%</sub>	ALNE <sub>200lx,50%</sub>	SS_ALNE <sub>60lx,50%</sub>	SS_ALNE <sub>200lx,50%</sub>
<b>Média</b>	65,55	32,9	54,67	21,78
<b>E. P. Média</b>	0,14	0,12	0,18	0,11
<b>Moda</b>	100	0	100	0
<b>Desvio Padrão</b>	26,43	22,62	33,32	21,32
<b>Variância</b>	698,45	511,72	1110,34	454,55
<b>Curtoses</b>	-0,67	-0,14	-1,22	1,79
<b>E. P. Curtoses</b>	0,03	0,03	0,03	0,03
<b>Curtose</b>	-22,33	-4,67	-40,67	59,67
<b>Skewness</b>	-0,32	0,45	-0,04	1,32
<b>E. P. Skewness</b>	0,01	0,01	0,01	0,01
<b>Z<sub>assimet.</sub></b>	-32	45	-4	132
<b>Intervalo</b>	100	100	100	100
<b>Mínimo</b>	0	0	0	0
<b>Máximo</b>	100	100	100	100
<b>Mediana</b>	65,09	33,26	53,3	16,2

As avaliações de curtose e assimetria das variáveis dependentes foram feitas apenas visualmente, utilizando-se os histogramas de frequência (

Figura 6), e pela identificação de valores positivos ou negativos (Tabela 3), não sendo calculadas as suas significâncias, devido ao tamanho da amostra ter mais de 200 casos, conforme recomendado por Field (2009). Avaliando-se a curtose, observou-se que a apenas a variável  $SS\_ALNE_{200lx,50\%}$  apresentou distribuição leptocúrtica. As demais apresentaram distribuição platicúrtica, logo com maior desvio padrão em relação à média. Quanto à simetria, a avaliação visual dos histogramas e dos valores positivos ou negativos para Skewness, confirmaram que todas as variáveis apresentaram distribuição assimétrica, em maior ou menor grau. Destaca-se que os histogramas das variáveis dependentes apresentaram curvas que remetem à curva normal, mas com picos laterais devido à saturação da variável área em função de uma iluminância alvo fixa. Isso, porque a métrica ALNE só identifica a superação da iluminância alvo, não contabilizando o quanto ela foi superada ou o quanto ela dista do alvo, perdendo a sensibilidade ao efeito das variações arquitetônicas no desempenho luminoso.

Figura 6 – Histogramas de frequência das variáveis de saída da simulação



Quanto à amplitude (Tabela 3), todas as variáveis dependentes apresentaram um intervalo igual a 100%, sendo o menor valor igual a zero e o maior igual a 100%, uma vez que correspondem à área dos ambientes (ALNE). A análise de desvio padrão mostra maior variação para  $ALNE_{60lx,50\%}$ , independentemente da condição da sacada. Observando-se os histogramas de frequências (



Figura 6), percebe-se que há uma predominância de casos em que 100% da área atinge 60 lux em 50% do tempo (~7.000 casos), retratando a limitação da métrica que não mostra a diferença de iluminação entre tais casos.

Os resultados apresentados indicam que possivelmente os dados terão que ser transformados para o treinamento das RNAs, a fim de se aumentar a sua precisão. Dentre as possibilidades estão a exclusão de dados e transformações por funções; e novos agrupamentos em função da variável Tvis, uma vez que nas análises dos ábacos, essa variável mostrou-se significativamente impactante, sendo necessária a proposição de ábacos individuais para os diferentes valores de Tvis (PEREIRA et al., 2020). Entende-se que grande parte dos valores de ALNE iguais a zero correspondem à Tvis 40%, enquanto grande parte dos valores iguais a 100% correspondem a Tvis 88%.


## 4.2 Metamodelos

Primeiramente, serão apresentados os resultados da definição do tamanho da camada oculta e da avaliação da necessidade de um índice geométrico como parâmetro de entrada das redes. Posteriormente, serão exibidos os resultados para as diferentes cidades.

### 4.2.1 Determinação da arquitetura da rede para Curitiba


Quanto ao tamanho da camada oculta observou-se a melhora no desempenho com o aumento da quantidade de neurônios. Para a escolha da melhor rede, além do desempenho, foi considerada a sua representatividade frente ao conjunto de redes treinadas. A partir das informações contidas na Figura 7 confirma-se que, dentre as redes sem índice geométrico, a rede com 28 neurônios ocultos, resultante da heurística de Upadhyaya-Eryurek (1992), foi a que apresentou menor MAE e menor desvios (RMSE). A aplicação dessa heurística para as redes com índice geométrico resultou em 31 neurônios para a camada oculta.

Figura 7 – MAE e RMSE para a rede com melhor desempenho do treinamento múltiplo para cada avaliação




Dando sequência para a análise dos índices geométricos, observou-se variação ínfima entre as redes com e sem índice. De maneira geral, o índice P e o RCR foram os que resultaram em redes com menores erros e desvios. O erro percentual absoluto médio (MAPE) dessas redes estão na ordem de ~7, enquanto a do conjunto de treinamento de ~4% e do conjunto de teste de ~15%. A avaliação do MAPE deve ser feita com cautela, uma vez que pode confundir a interpretação dos resultados para valores de ALNE muito baixos. O erro absoluto médio MAE e o desvio da média foram inferiores a 4% da área para todos os casos na avaliação global das redes, inferiores a 2% da área para o treinamento e de ~5% da área para o teste. Esses valores são pequenos em termos da percepção luminosa do ambiente.

Figura 8 – Comparação entre as opções de índices geométricos – dados globais (treinamento + teste)



Diante dos resultados apresentados anteriormente, em que as redes com índice P e RCR apresentaram os melhores desempenhos, escolheu-se o índice P para dar sequência ao estudo. Isso, porque esse índice é compatível com o método simplificado da proposta da norma NBR 15.575, para aplicação do Ábacos (PEREIRA, et al., 2020). Salienta-se que a diferença de desempenho entre os índices, e mesmo a opção sem índice, foi muito pequena, não devendo ser consideradas inadequadas as outras opções aqui não escolhidas. A Figura 9 traz os resultados simulados e preditos pela rede índice P para os dois parâmetros de saída. Apesar dos erros absolutos percentuais médios (MAPE) considerados elevados, em especial para o conjunto de teste, ~15%, as regressões apresentaram correlação forte com  $R^2$  igual a 0,9667 para  $ALNE_{60lx,50\%}$  e  $R^2$  igual a 0,9669 para  $ALNE_{200lx,50\%}$ . Além disso, uma análise de histogramas de frequência de ocorrência do MAPE, individualizados por parâmetro de saída e conjunto de treinamento e teste permitiu a identificação de uma clara distribuição assimétrica à esquerda com cauda longa, indicando um volume muito maior de dados com erros menores do que 15%.

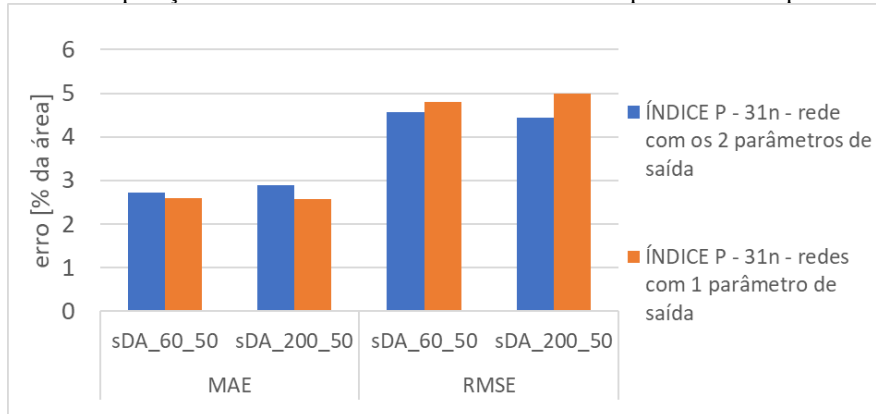
Figura 9 – Correlação simples entre os resultados simulados no DIVA e os estimados pela RNA Índice P



Diante dos resultados obtidos, foram treinadas novas redes Índice P com os parâmetros de saída individualizados. As novas redes foram treinadas com as mesmas configurações de treinamento das anteriores. A única diferença consistiu na arquitetura, com a alteração da camada de saída, sendo composta por apenas um neurônio, ao invés de dois. A Figura 10 apresenta os resultados comparativos entre a rede Índice P com os dois parâmetros de saída, já apresentada anteriormente, e as novas redes, cada uma com um parâmetro de

saída, uma com  $ALNE_{60lx,50\%}$  e a outra com  $ALNE_{200lx,50\%}$ . Todos os resultados correspondem à rede de melhor desempenho, dentre as 5 treinadas, para cada alternativa avaliada. Essa análise mostrou que apesar do erro absoluto médio (MAE) ter diminuído para os dois parâmetros de saída com a individualização das redes, a raiz do erro quadrático médio (RMSE) aumentou, indicando o aumento dos desvios em relação à média. Como o RMSE é sensível aos discrepantes, pois assim como o erro quadrático médio (MSE) penaliza previsões muito distantes, e como o MAE diminuiu, esse resultado indica o aumento da ocorrência ou da amplitude dos discrepantes.

Figura 10 – Comparação entre a rede Índice P com ambos os outputs e com outputs individuais

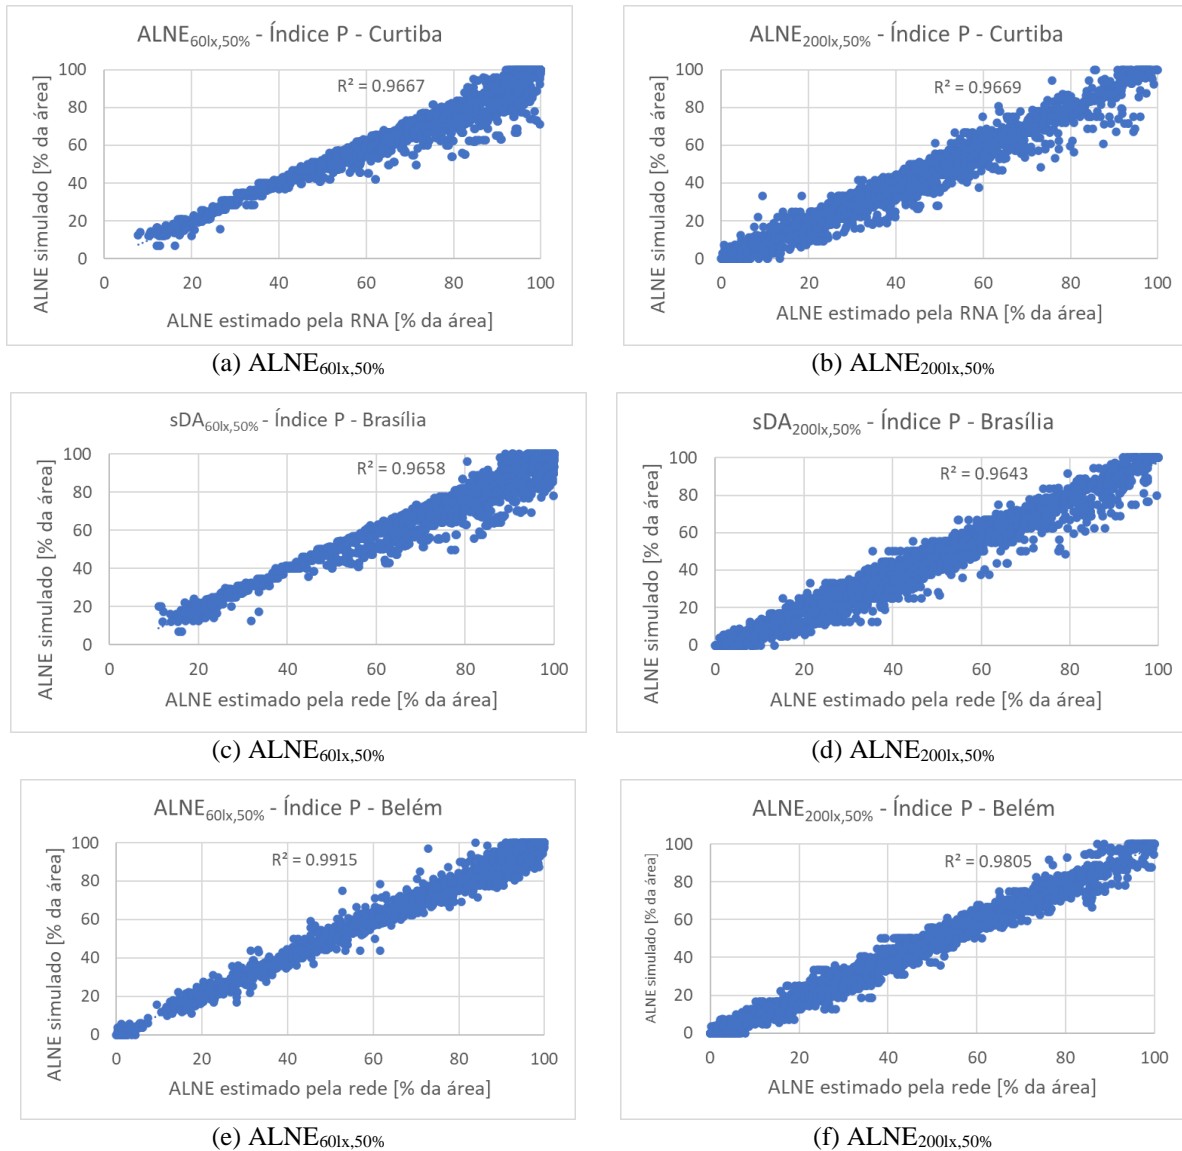


A análise de correlação simples entre os valores simulados e preditos pelas redes indicou a perda de precisão dos modelos com a separação dos parâmetros de saída em redes individuais. O  $R^2$  que anteriormente era de 0,9667 e 0,9669 para  $ALNE_{60lx,50\%}$  e  $ALNE_{200lx,50\%}$ , respectivamente (Figura 9), diminuiu para 0,9658 e 0,9628. De maneira geral, todos os resultados foram próximos, indicando que ~ 96% da variância dos dados pode ser explicada pelo modelo (a reta), enquanto ~ 4% tratam de uma variância residual.

#### 4.2.2 Redes para as outras cidades representativas.

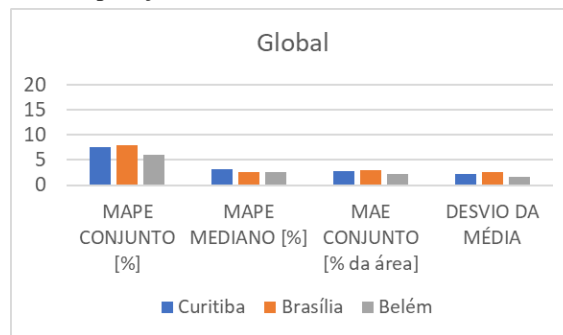
Dada a desvantagem da individualização dos parâmetros de saída em redes distintas, a configuração inicial a rede índice P, com os dois parâmetros, foi escolhida para o treinamento das redes para Brasília e Belém. A Figura 11 mostra os gráficos de correlação linear simples entre os resultados simulados e preditos pelas redes para as três cidades, Curitiba, Brasília e Belém, para cada um dos parâmetros de saída. Os valores de  $R^2$  para Brasília (c, d) foram muito similares aos de Curitiba (a, b), 0,9658 e 0,9643 para  $ALNE_{60lx,50\%}$  e  $ALNE_{200lx,50\%}$ , respectivamente. Já a rede de Belém (e, f) apresentou correlação mais forte entre os resultados simulados e preditos, com  $R^2$  de 0,9916 e 0,9805 para  $ALNE_{60lx,50\%}$  e  $ALNE_{200lx,50\%}$ , respectivamente. Para essa cidade, nota-se maior precisão das estimativas de  $ALNE$  maior do que 70% da área, para  $ALNE_{60lx,50\%}$ , em relação aos modelos das outras duas cidades. Já para  $ALNE_{200lx,50\%}$ , os desvios foram reduzidos de maneira geral.

Figura 11 — Correlação simples entre os resultados simulados e os estimados pelas RNAs Índice P




Os resultados apresentados na Figura12 mostram que o desempenho superior da rede de Belém em relação às demais deve-se ao seu melhor poder de generalização, explicitado pelos menores erros obtidos para o conjunto de teste. Essa rede apresentou menor convergência no treinamento, mas em virtude dos erros do conjunto de teste serem maiores, o desempenho global da rede foi superior. Esse resultado indica que pode estar ocorrendo o treinamento excessivo das outras redes. A diferença entre o desempenho das redes pode estar associada ao efeito da latitude na complexidade do problema a ser aprendido. As cidades diferem em cerca de  $10^\circ$  de latitude, o que faz o efeito da obstrução na ALNE variar significativamente de uma cidade para a outra. Soma-se, o efeito da latitude combinado com a orientação. Para Belém, a diferença entre as orientações é muito menor do que para Curitiba e Brasília.


Figura 12 – Comparação entre as 3 cidades (rede de melhor desempenho)



(a) Erros da rede (treinamento e teste)



(b) erros do conjunto de treinamento

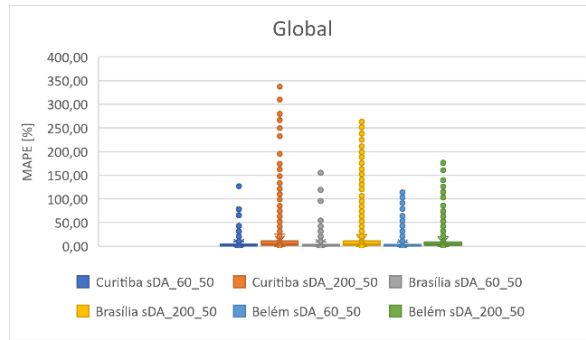


(c) erros do conjunto de teste


Observando-se os erros dos parâmetros de saída independentemente,

Figura 13, nota-se claramente a redução dos discrepantes ocorridos para  $ALNE_{200lx,50\%}$ , tanto no treinamento, quanto no teste de Curitiba para Brasília e de Brasília para Belém. Já para  $ALNE_{60lx,50\%}$  a variação dos discrepantes entre as cidades foi menor, sendo que Belém apresentou discrepantes equivalentes aos encontrados para  $ALNE_{200lx,50\%}$ , para o treinamento. O intervalo interquartilico, bem como o limite máximo foi maior para  $ALNE_{200lx,50\%}$  para as 3 cidades, indicando que independentemente da latitude, o aprendizado dessa variável é mais complexo para as redes.

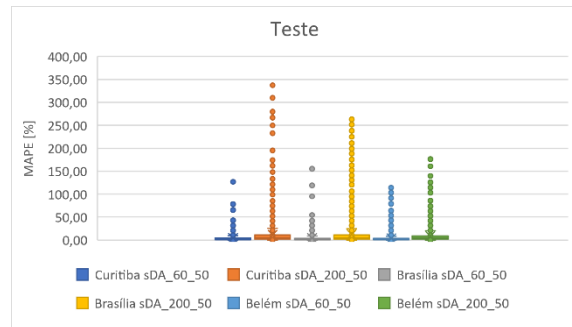
Figura 13 — Diagrama de caixas para as 3 cidades (rede de melhor desempenho)



(a) MAPE da rede (treinamento e teste)



(b) MAPE do conjunto de treinamento



(c) MAPE do conjunto de teste

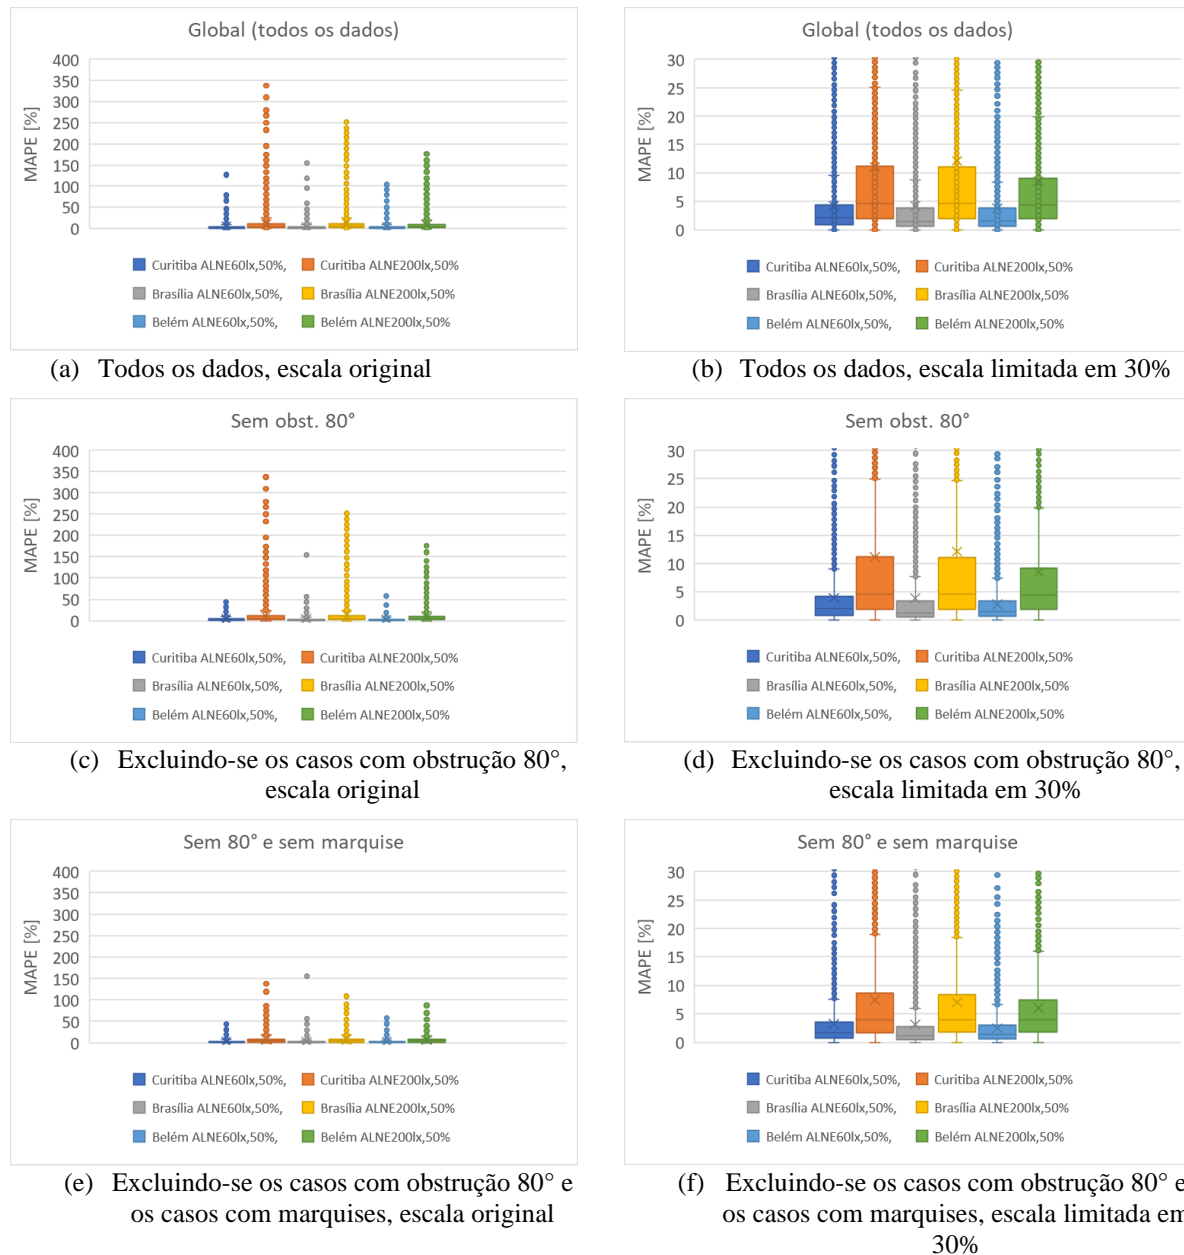
A



Figura 14 mostra o procedimento de tentativa de redução dos discrepantes pela limitação de aplicação das redes para de ângulo obstrução de 80.º, e somando a exclusão das marquises à limitação da obstrução. A figura mostra os mesmos gráficos em duas escalas, a escala original e uma escala permitindo a análise dos quartis, limitada a MAPE 30%. Nessa última escala é possível constatar que a maior parte dos dados, o intervalo interquartilico, encontra-se dentro de uma faixa de erro percentual (MAPE) inferior a 5% para  $ALNE_{60lx,50\%}$  e inferior a 12% para  $ALNE_{200lx,50\%}$  para o conjunto total de dados e quando se exclui obstruções com ângulo de 80.º. Quando as marquises também são excluídas a  $ALNE_{200lx,50\%}$  torna-se inferior a 10%. A primeira alteração, a exclusão das obstruções 80.º, foi mais significativa para a redução dos discrepantes de  $ALNE_{60lx,50\%}$ , enquanto a segunda, reduziu os erros de maneira geral.

Vale destacar que essa análise foi feita apenas filtrando-se os resultados dos modelos, recomenda-se avaliar o efeito de se treinar novas redes sem o ângulo de obstrução filtrado e individualizar redes pela característica da marquise para avaliar o seu desempenho e viabilidade.

Figura 14 — Diagrama de caixas para as 3 cidades, (rede de melhor desempenho) — avaliação dos discrepantes



## 5. CONCLUSÕES

Esse trabalho teve por objetivo propor um metamodelo, utilizando-se redes neurais artificiais, para verificar o desempenho luminoso de edificações residenciais, considerando o impacto do entorno construído no contexto da revisão da norma brasileira ABNT NBR 15.575-1 Edificações habitacionais — Desempenho (ABNT, 2021). Como base de dados adotou-se o mesmo conjunto simulado para a elaboração dos Ábacos do método simplificado proposto para a revisão dessa norma a ser enviado para consulta pública pelo grupo do Laboratório de Conforto Ambiental da Universidade Federal de Santa Catarina (MARIANO; *et al.*, 2020, PEREIRA; *et al.*, 2020, GIRALDO; *et al.*, 2021). A base de dados foi gerada e

validada por 9 pacotes de simulação e 130.272 casos simulados, constituindo-se em uma base robusta. A ferramenta foi proposta com desempenho global aceitável, com erro percentual médio menor do que 10%, sendo necessária o seu refinamento para a redução de discrepantes. Vale ressaltar que as redes deste trabalho foram testadas apenas com um conjunto de dados nunca vistos específicos, tornando a sua avaliação bastante rigorosa e devem ser testadas também de maneira randômica. Além disso, destaca-se que os erros percentuais absolutos médios devem ser analisados com cautela, pois quando o valor de ALNE é muito pequeno, o MAPE resulta em um valor muito alto, distorcendo a avaliação de acuracidade da rede.

Quanto às possibilidades estruturais testadas para as redes, a alternativa de separação dos parâmetros de saída em redes distintas foi descartada. Já a limitação dos metamodelos em função da obstrução deve ser avaliada mais detalhadamente, uma vez que a redução dos discrepantes teve impacto diferenciado entre as cidades. Se para Belém limitar os ângulos de obstrução externa a  $70^\circ$  é suficiente, para Curitiba a limitação pode remeter a ângulos ainda menores.

Recomenda-se para trabalhos futuros o refinamento do metamodelo e a ampliação do seu escopo. No primeiro caso, recomenda-se testar outros algoritmos, como o gradiente descendente (THE MATHWORKS INC., 2014) e Levenberg Maquardt (SILVA; ALMEIDA; YAMAKAMI, 2012); outras alternativas de divisão do conjunto de dados entre treinamento e teste, uma vez que o método adotado não avaliou a rede com a divisão randômica dos dados que é menos restritiva, sugere-se o método da validação cruzada; um novo ajuste de neurônios ocultos, conforme a alteração do conjunto de dados das cidades; diferentes limitações de escopo das redes visando reduzir discrepantes; e ampliação do conjunto de treinamento, utilizando-se a mesma base de dados dos ábacos apenas para treinamento, acrescentando-se mais proporções para a largura 3,75, de forma a uniformizar a malha de pontos apresentada na

Figura 2, e simulando-se novos casos para teste. Quanto à ampliação do seu escopo, recomenda-se testar modelos com as outras transmissões visíveis que compõe a base de dados.

## REFERÊNCIAS BIBLIOGRÁFICAS

ANDRADE, Max L. V. X. de; CHENG, Liang-Yee. Diretrizes Geométricas de Auxílio ao Processo de Projeto de Edifícios Residenciais. **Anais... SIGraDI 2006**, Santiago, Nov. 2006.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 15575-1**: Edificações habitacionais — Desempenho, Parte 1: Requisitos gerais. Rio de Janeiro, 2021. 89 p. ISBN: 978-85-07-08724-3 98p

BOCANEGRA, C. W. R. **Procedimento para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes**. Dissertação (mestrado). Departamento de Engenharia Civil, Universidade de São Paulo, São Carlos, 2002. 97 p.

CONFEDERAÇÃO NACIONAL DA INDÚSTRIA – CIN. **Retratos da Sociedade Brasileira – Flexibilidade no mercado de trabalho**. Ano 6. N 37. Janeiro de 2017. Disponível em: < [https://bucket-gw-cni-static-cms-si.s3.amazonaws.com/media/filer\\_public/31/21/31217ed5-7485-4678-8c2b-d7c04d0a1583/retratosdasociedadebrasileira\\_37\\_flexibilidade1.pdf](https://bucket-gw-cni-static-cms-si.s3.amazonaws.com/media/filer_public/31/21/31217ed5-7485-4678-8c2b-d7c04d0a1583/retratosdasociedadebrasileira_37_flexibilidade1.pdf)>. Acesso em: 01/10/2019.

COSTA, S. M. S. Metodologia de Sistemas Flexíveis aplicada a estudos em Ciências da Informação: uma experiência pedagógica. **Transinformação**, v. 15, n. 2, mai. /agos., p. 259-271. 2003.

CRAWLEY, D. e LAWRIE, L, 2018 Climate.OneBuilding.Org.- Repository of free climate data for building performance simulation. **Arquivos climáticos TMYx para o Brasil**. Disponível em: < <http://climate.onebuilding.org/>>. Acesso em: novembro de 2018.

FIELD, A. **Descobrimo a estatística usando o SPSS**. [recurso eletrônico] 2ed. Porto Alegre: Artmed, 2009. ISBN 978-85-363-2018-2. Obra originalmente publicada sob o título Discovering Statistics with SPSS 2nd Edition ISBN 0-71619-4452-4

FONSECA, R. W. **Iluminação natural e consumo energético de edificações não residenciais: as possibilidades e as limitações da aplicação de redes neurais artificiais**. Tese (doutorado) Departamento de Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2015. 457p.

FONSECA, R. W.; PEREIRA, F. O. R. Metamodeling of the Energy Consumption of Buildings with Daylight Harvesting – Application of Artificial Neural Networks Sensitive to Orientation. **Journal of Daylighting**, v.8, issue 2, pp.255-269 DOI [10.15627/jd.2021.20](https://doi.org/10.15627/jd.2021.20)

FONSECA, R.W. **Variáveis geográficas e climáticas e o consumo energético de iluminação em edificações**. Relatório de Pós-doutorado. Programa de Pós-graduação em Engenharia Civil, Universidade Federal de Santa Catarina. 2018. 84 p.

FREE SOFTWARE FOUNDATION. **GNU PSPP** Statistical Analysis Software Release v. 1.2.0-g0fb4db. 2016. PSPP é um programa de distribuição livre para análise estatística.

GALAFASSI, M. **Impacto do Método Prescritivo do RTQ-C no processo de projeto arquitetônico de edificações: a visão de arquitetos em Florianópolis – SC**. Dissertação (mestrado) – Pós-Graduação em Arquitetura e Urbanismo, Universidade Federal de Santa Catarina, Florianópolis/SC, 2012.

GIRALDO, N. V., FONSECA, R. W., MARIANO, P., PEREIRA, F. O. R. DL Abacus- A simplified simulation-based tool for daylighting performance assessment in Brazilian dwellings. **Anais ... Building Simulation Conference**. 1-3 de setembro de 2021, Bruxelas, Bélgica. 8 p.

GONSALVES, A. **Trabalho Home Office – Guia Prático 2020**. Hostinger Tutorials. Disponível em: <<https://www.hostinger.com.br/tutoriais/guia-de-trabalho-home-office-vagas/>>. Acesso em: 01/10/2020.

HAYKIN, S. **Redes Neurais: Princípios e Práticas**.2:Porto Alegre: ARTMED Editora S.A. 2001. 900 p.

HECHT-NIELSEN, R. Kolmogorov's mapping neural network existence theorem. **Anais ... Proceedings IEEE International Conference on Neural Networks**. San Diego: SOS Printing. 18 a 29 de junho, 1987. p. 11-14. 1987.

ILLUMINATING ENGINEERING SOCIETY – IES. **Approved Method: IES Spatial Daylight Autonomy (sDA) and Annual Sunlight Exposure (ASE) - IES LM-83-12**. Illuminating Engineering Society of North America. Nova Iorque. 2012. 12 p.

INSTITUTO NACIONAL DE METROLOGIA, QUALIDADE E TECNOLOGIA – INMETRO. **PORTARIA Nº 309, DE 6 DE SETEMBRO DE 2022 Aprova as Instruções Normativas e os Requisitos de Avaliação da Conformidade para a Eficiência Energética das Edificações Comerciais, de Serviços e Públicas e Residenciais – Consolidado**. Ministério da economia. Disponível em <[http://www.inmetro.gov.br/legislacao/detalhe.asp?seq\\_classe=1&seq\\_ato=2989](http://www.inmetro.gov.br/legislacao/detalhe.asp?seq_classe=1&seq_ato=2989)>. Acesso em: 30/03/2023. 295p.

LADYBUG TOOLS LCC. **Honeybee**. Honeybee creates, runs, and visualizes daylight simulations using Radiance and energy models using OpenStudio and EnergyPlus. É um *plug-in* de modelagem de iluminação natural e energia altamente otimizado para o modelador Rhinoceros - NURBS. 2022.

LORENZ, C. L. et al. Artificial Neural Networks for parametric daylight design. **Architectural Science Review**, 63:2, 210-221, 2019 DOI: [10.1080/00038628.2019.1700901](https://doi.org/10.1080/00038628.2019.1700901)

LU, C., LI, S., LU, Z. Building energy prediction using artificial neural networks: A literature survey. **Energy and Buildings**, v. 262, 1 May 2022, 111718. DOI: [1016/j.enbuild.2021.111718](https://doi.org/10.1016/j.enbuild.2021.111718)

MARIANO, P.O.P., FONSECA, R.W., PEREIRA. F.O.R. and PEREIRA, A. T. C. Autonomous Parametric Process for Daylight Simulation Applied to the Proposal of a Daylighting Performance Tool. *Anais ... Proceedings of SIGRADI*. Medellin (Colombia), 2020, pp. 534–540.

MARSH, A. **Software development**. Base de aplicativos para estimativas da iluminação natural. Disponível em: < <http://andrewmarsh.com/software/> >. Acessado em: 30/03/2023.

MATHWORKS. **Matlab e Simulink**. Matlab é uma linguagem de programação multiparadigma e ambiente de computação numérica. 2020.

MICROSOFT. **Microsoft Excel**. O Microsoft Excel é uma planilha para Windows, macOS, Android e IOS que possui cálculo, ferramentas de gráficos, tabelas dinâmicas e uma linguagem de programação de macro chamada Visual Basic for Applications. OFFICE 2020.

MCNEEL, R.; ASSOCIATES. **Rhinoceros 3D**. v.6. Rhinoceros 3D é um programa de modelagem tridimensional baseado na tecnologia NURBS. 2019.

NCE-UFRJ. **Dicas para a configuração de redes neurais**. Instituto Tércio Pacitti de Aplicações e Pesquisas Computacionais. Centro de ciências matemáticas e da natureza. Universidade Federal do Rio de Janeiro. 4p. Disponível em: < [http://www.nce.ufrj.br/labic/downloads/dicas\\_cfg\\_rna.pdf](http://www.nce.ufrj.br/labic/downloads/dicas_cfg_rna.pdf) >. Acesso em: 19/11/2020.

NGARAMBE, J, ADILKHANOVA, I, UWIRAGIYE, B, YUN, G. Y. A review on the current usage of machine learning tools for daylighting design and control. **Building and Environment**, V. 223, Sept. 2022, 109507. <https://doi.org/10.1016/j.buildenv.2022.109507>

PACINI, S.; TOBLER, R.; BITTENCOURT, V. S. **Tendências do home office no Brasil. Portal Fundação Getúlio Vargas**. Economics, 16 de março de 2023. Disponível em: < <https://portal.fgv.br/en/node/28262> >. Acesso em 30/03/2023.

PEREIRA, F. O. R.; *et al*. An Investigation about the Consideration of Daylighting along the Design Stages. *Anais ... Passive and Low Energy Architecture - PLEA, 2005: Environmental Sustainability - The Challenge of Awareness in Developing Societies*. Beirute, 2005. p. 1025-1030. 2005.

PEREIRA, F. O. R.; *et al*. Ferramenta simplificada para a estimativa do desempenho da iluminação natural em edificações residenciais. *Anais ... XVIII Encontro Nacional de Tecnologia do Ambiente Construído*, Porto Alegre 4 a 6 de novembro de 2020. ANTAC: Porto alegre. 8p.

PEREIRA, F. O.R., FONSECA, R. W., SCALCO, V. A. **Considerações sobre a avaliação do desempenho da iluminação natural através da ABNT NBR 15575/2013**. Revista Lumière Electric, São Paulo, p. 50 - 52, 01 abr. 2017

PEREIRA, F. O.R.; SCHMITT, M.; MORAES L. Zoneamento luminoso do território brasileiro através de histogramas de frequência acumulada de ocorrência de iluminâncias

horizontais difusas externa. **Anais ... XIII Encontro Nacional e IX Encontro Latino-americano de Conforto no Ambiente Construído**. Campinas-SP. 2015. 10p

PONTUAL, J. A. F. M. C. **50, 60, 70 Formas de moradia no brasil: entre os 50 e os 70**. 263 f. Dissertação (mestrado). Curso de Design, Departamento de Design da Universidade Federal de Pernambuco, Universidade Federal de Pernambuco, Recife, 2009.

QUEIROZ, P. V.S. **Mensuração do consumo de energia elétrica: algoritmo para detecção de potenciais usuários da termoacumulação como alternativa para deslocamento de carga**. Dissertação (mestrado) Programa de Pós-graduação em Metrologia da PUC-Rio, Pontifícia Universidade de Católica do Rio de Janeiro, Rio de Janeiro, 2011. 98p.

REINHART, C. F. Lightswitch-2002: A model for manual and automated control of electric lighting and blinds. *Solar Energy* 77 (2004) 15–28 doi:10.1016/j.solener.2004.04.003

SILVA, R. M.; ALMEIDA, T. A.; YAMAKAMI, A. Análise de desempenho de redes neurais artificiais para classificação automática de web spam. **Revista Brasileira de Computação Aplicada**, v. 4, n. 2, outubro, p. 42-57. 2012.

SILVA, A. N. R. D., *et al*. **SIG: Uma plataforma para introdução de técnicas emergentes no planejamento urbano, regional e de transportes - Uma ferramenta 3D para análise ambiental urbana, avaliação multicritério e redes neurais artificiais**.1: São Paulo: Ed. dos Autores. 2004. 227 p.

SOLEMMA LLC. **Climate Studio**: Advanced daylighting, electric lighting, and conceptual thermal analysis. É um *plug-in* de modelagem de iluminação natural e energia altamente otimizado para o modelador Rhinoceros - NURBS. 2022.

SOLEMMA LLC. **DIVA for Rhino: Environmental Analysis for Buildings**. DIVA-for-Rhino é um *plug-in* de modelagem de iluminação natural e energia altamente otimizado para o modelador Rhinoceros - NURBS. 2020.

THE MATHWORKS INC. **MATLAB Documentation**. Natick: The Mathworks Inc. 2014.

UPADHYAYA, B. R.; EVREN, E. Application of Neural Networks for Sensor Validation and Plant Monitoring. **Nuclear Technology**, v. 97, p. 170-176. 1992.

VELUX. **Daylight Visualizer for Windows**. VELUX Daylight Visualizer is a professional lighting simulation tool for the analysis of daylight conditions in buildings. Disponível em: < <https://www.velux.com/what-we-do/digital-tools/daylight-visualizer/download-for-windows> >. Acessado em 30 /03/2023.

Fonseca, R. W.; Mariano, P. O. P; *et. al*; Redes neurais artificiais para estimar a iluminação natural em ambientes residenciais com obstrução do entorno. E&S - Engineering and Science, 2023, 12:2.