

Mauricio Nath Lopes

**DESENVOLVIMENTO DE METAMODELO PARA A
DETERMINAÇÃO DO CONSUMO ANUAL EM
CLIMATIZAÇÃO APLICADO A EDIFÍCIOS DE ESCRITÓRIOS
COM SISTEMAS DO TIPO ÁGUA GELADA EM DIFERENTES
CLIMAS**

Tese submetida ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Santa Catarina para a obtenção do Grau de Doutor em Engenharia Civil.

Orientador: Prof. Roberto Lamberts, PhD.

Florianópolis
2019

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Lopes, Mauricio Nath
DESENVOLVIMENTO DE METAMODELO PARA A
DETERMINAÇÃO DO CONSUMO ANUAL EM CLIMATIZAÇÃO
APLICADO A EDIFÍCIOS DE ESCRITÓRIOS COM SISTEMAS DO
TIPO ÁGUA GELADA EM DIFERENTES CLIMAS / Mauricio
Nath Lopes ; orientador, Roberto Lamberts, 2019.
205 p.

Tese (doutorado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós
Graduação em Engenharia Civil, Florianópolis, 2019.

Inclui referências.

1. Engenharia Civil. 2. consumo de sistemas de
climatização. 3. redes neurais artificiais. 4.
indicador climático. 5. predição de consumo em
edificações. I. Lamberts, Roberto. II. Universidade
Federal de Santa Catarina. Programa de Pós-Graduação
em Engenharia Civil. III. Título.

Mauricio Nath Lopes

**DESENVOLVIMENTO DE METAMODELO PARA A
DETERMINAÇÃO DO CONSUMO ANUAL EM
CLIMATIZAÇÃO APLICADO A EDIFÍCIOS DE ESCRITÓRIOS
COM SISTEMAS DO TIPO ÁGUA GELADA EM DIFERENTES
CLIMAS**

Esta Tese foi julgada adequada para obtenção do Título de Doutor em Engenharia Civil e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Santa Catarina-UFSC.

Florianópolis, 08 de março de 2019.

Prof. Glicério Trichês, Dr. Eng.
Coordenador do Curso

Banca Examinadora:

Prof. Roberto Lamberts, PhD. (Orientador)
Universidade Federal de Santa Catarina - UFSC

Prof. Paulo Smith Schneider, Dr.Eng.
Universidade Federal do Rio Grande do Sul - UFRGS

Prof. Nathan Mendes, Dr. Eng.
Pontifícia Universidade Católica do Paraná – PUC-PR

Prof. Fernando Simon Westphal, Dr. Eng.
Universidade Federal de Santa Catarina - UFSC

Prof. Ricardo Rütther, PhD.
Universidade Federal de Santa Catarina - UFSC

Prof.^a Ana Paula Melo, Dr.^a Eng.
Universidade Federal de Santa Catarina- UFSC

AGRADECIMENTOS

Gostaria de agradecer a colaboração que recebi durante o período em que me dediquei à realização deste trabalho.

Ao meu orientador, Prof. Roberto Lamberts, pela oportunidade de trabalharmos juntos no Laboratório de Eficiência Energética em Edificações (LabEEE/UFSC), durante a última década. Agradeço pelas suas orientações, incentivo, apoio e amizade, que sempre estiveram presentes neste período.

Aos professores da UFSC, com os quais cursei disciplinas durante o doutorado, que contribuíram para o meu aperfeiçoamento profissional.

Aos professores que participaram das bancas de qualificação e doutorado, pelas relevantes contribuições que fizeram para a melhoria do presente trabalho.

Aos colegas do LabEEE que durante este longo período tive o prazer de conhecer. Em especial, à Joyce Carlo, Ana Paula Melo, Rogério Versage, Márcio Sorgato, Leonardo Mazzaferro e Gustavo Olegário, que compartilharam seus conhecimentos e experiência no desenvolvimento de metamodelos e no uso de redes neurais artificiais.

Ao Instituto Federal de Santa Catarina (IFSC), que através de seu programa de apoio à capacitação de professores, me concedeu afastamento remunerado durante três anos.

Por fim, e acima de tudo, agradeço a minha família. Meus pais, Luiz Clóvis e Maria Lourdes, pelo esforço e empenho que dedicaram à minha educação. E em especial, à minha esposa, Lucila, que além de prestar apoio na elaboração deste trabalho, sempre me incentivou e motivou.

RESUMO

O consumo do sistema de climatização representa uma parcela significativa do consumo total de energia em edificações comerciais. Estimar o consumo de energia dos sistemas de climatização em condições reais de operação, devido à complexidade destes sistemas, não é uma tarefa fácil. A simulação é um método detalhado que apresenta bons resultados, mas a sua complexidade é o maior obstáculo para uma adoção mais ampla na prática. Os métodos simplificados existentes apresentam imprecisões significativas, e geralmente estimam somente a carga térmica da edificação. O objetivo desta tese foi desenvolver um método simplificado que permitisse estimar o consumo de energia anual de sistemas de climatização do tipo água gelada em edifícios de escritórios, a partir do conhecimento da carga térmica integrada anual da edificação, das características do sistema de climatização, e do clima. A estratégia adotada consistiu em gerar uma base de dados a partir da simulação de um conjunto significativo de casos, e depois treinar redes neurais artificiais com o uso destes dados. Um novo indicador climático, o *cooling enthalpy hours* (CEH), foi proposto e avaliado para representar os climas brasileiros. Análise de sensibilidade pelo método Sobol foi empregada para reduzir a quantidade de casos simulados. A base de dados foi obtida através da simulação de 250.000 casos no EnergyPlus. Os dados gerados foram pré-processados. Um estudo foi realizado para definir o tamanho da amostra a ser empregado no treinamento das redes neurais. Os resultados demonstraram que, nesta pesquisa, o uso de uma amostra correspondente a 15% da população é adequado ao treinamento. Redes neurais artificiais com diferentes quantidades de neurônios na camada interna foram treinadas, e os resultados mostraram que 32 neurônios na camada interna apresenta a melhor relação custo-benefício para a arquitetura de rede inicialmente idealizada. A predição de consumo realizada com o este metamodelo (RNA 32) apresentou erros elevados (superior a 40%) nos casos com climas amenos, levando a restringir o uso do metamodelo para cidades com CEH superior a 50.000. A influência da inclusão, exclusão ou alteração de variáveis de entrada também foi avaliada, e dois novos metamodelos foram obtidos (RNA 35_COP e RNA 29_sHIS). Estes três metamodelos foram utilizados para prever o consumo anual do sistema de climatização de 66.300 novos casos, chamados casos não vistos. Todos os metamodelos apresentaram um bom desempenho, sendo escolhido como metamodelo final desta tese aquele que possuía a arquitetura de rede neural mais

simplificada (RNA 29_sHIS = 14 neurônios de entrada, 29 neurônios na camada interna e 1 neurônio de saída), que apresentou $R^2=0,9789$ e $NRMSE=0,063788$ ao prever o consumo dos casos não vistos, e $R^2=0,9858$ e $NRMSE=0,067961$ ao prever o consumo dos casos da base de dados. Os erros percentuais foram inferiores a 15% em 98,4% dos casos quando o consumo foi previsto para os casos da base de dados, e em 97,5% dos casos quando o consumo foi previsto para os casos não vistos. Outra avaliação demonstrou que o metamodelo manteve o bom desempenho independente do nível de radiação solar do clima.

Palavras chaves: consumo de sistemas de climatização, indicador climático, redes neurais artificiais, previsão de consumo em edificações.

ABSTRACT

The HVAC system consumption represents a significant portion of the total energy consumption in commercial buildings. Predicting the energy consumption of HVAC systems under actual operating conditions is not an easy task due to the complexity of these systems. Simulation is a detailed method which produces good results, but its complexity is the biggest obstacle to wider adoption in practice. The existing simplified methods present significant inaccuracies, and generally estimate only the demand for thermal energy. The objective of this thesis was to develop a simplified method to predict the annual cooling energy consumption of chilled water type air conditioning systems in office buildings from the building's integrated annual thermal load, HVAC system characteristics and weather. The strategy adopted was to generate a database from the simulation of a significant number of cases, and then to train artificial neural networks with the use of these data. A new climate indicator, the cooling enthalpy hours (CEH), was proposed and evaluated to represent the different Brazilian climates. Sobol sensibility analysis was used to reduce the number of simulated cases. The database was obtained from the simulation of a sample of 250,000 cases in EnergyPlus. The data were pre-processed. A study was carried out to define the sample size to be used in the training of neural networks. The results showed that the use of a sample corresponding to 15% of the population is adequate for the training in this research. Artificial neural networks were trained with different amounts of neurons in the hidden layer. The results showed that 32 neurons in the hidden layer presents the best cost-benefit relation for the initially idealized network architecture. Predictions with this metamodel (RNA 32) presented high errors (over 40%) in cases with mild climates, leading to restricting the use of the metamodel for cities with CEH higher than 50,000. The influence of the inclusion, exclusion or change of input variables was also evaluated, and two new metamodels were obtained (RNA 35_COP and RNA 29_sHIS). These three metamodels were used to predict the annual consumption of the HVAC system of 66,300 new cases, called unseed cases. All metamodels presented a good performance, being chosen as the final metamodel the one with simpler neural network architecture (RNA 29_sHIS = 14 input neurons, 29 neurons in the hidden layer and 1 output neuron), which presented $R^2 = 0.9789$ and $NRMSE = 0.063788$ when predicting the consumption of the unseen cases, and $R^2 = 0.9858$ and $NRMSE = 0.067961$ when predicting consumption of the cases in the database. Percentage errors

were less than 15% in 98.4% of cases when consumption was predicted for the database's cases and in 97.5% of cases when consumption was predicted for unseen cases. Another evaluation demonstrated that the metamodel maintained a good performance, regardless of the radiation level of the city considered.

Keywords: HVAC energy consumption, climate indicator, artificial neural network, building prediction model.

LISTA DE FIGURAS

Figura 1 - Diagrama esquemático de uma rede neural multicamada.....	39
Figura 2 – Típico sistema de climatização do tipo água gelada (Fonte: Autor).....	55
Figura 3 – Fases e etapas da pesquisa	67
Figura 4 – Geometria típica utilizada e suas zonas térmicas.....	69
Figura 5 – Possíveis horários de funcionamento nos dias de semana. ..	80
Figura 6 - Perfil de frequência de carga térmica - caso base (Rio de Janeiro-RJ).....	99
Figura 7 – Regressão linear relacionando a carga térmica integrada anual de refrigeração e o indicador climático CDH de 20 cidades brasileiras (temperatura base=18°C).....	100
Figura 8 – Regressão linear relacionando a carga térmica integrada anual de refrigeração e o CDH de 20 cidades brasileiras, considerando somente as horas de funcionamento do sistema de climatização (temperatura base = 18°C).....	102
Figura 9 – Regressão linear relacionando a carga térmica integrada anual de refrigeração e o CEH de 20 cidades brasileiras (entalpia base = 35 kJ/kg e temperatura base = 18°C).....	103
Figura 10 – Regressão linear relacionando a carga térmica integrada anual de refrigeração e o CEH de 20 cidades brasileiras, considerando somente as horas de funcionamento do sistema de climatização (entalpia base = 35 kJ/kg e temperatura base = 18°C).....	104
Figura 11 – Regressão linear relacionando a carga térmica integrada anual de refrigeração e o CDH_H de 407 cidades brasileiras (entalpia base = 35 kJ/kg).....	106
Figura 12 – Regressão linear relacionando a carga térmica integrada anual de refrigeração e o CEH de 407 cidades brasileiras (entalpia base = 35 kJ/kg e temperatura base = 18°C).....	106
Figura 13 – Gráfico de frequência das 407 cidades nos 18 grupos criados com o CEH.....	107
Figura 14 – Desvio padrão dos valores da variável “índice de ocupação” para diferentes tamanhos de amostra.....	123
Figura 15 – Relação entre a razão carga térmica anual/COP e consumo.....	125

Figura 16 – Relação entre a razão carga térmica anual/IPLV e consumo.	126
Figura 17 – Distribuição de frequência da carga térmica anual de refrigeração: (a) antes da transformação e (b) depois da transformação.	129
Figura 18 – Distribuição de frequência do consumo do sistema de climatização: (a) antes da transformação e (b) depois da transformação.	130
Figura 19 – Consumo predito versus consumo simulado (RNA 32 = 18 neurônios de entrada, 32 na camada interna e 1 neurônio de saída). ..	133
Figura 20 – Erro percentual da predição de consumo do sistema de climatização com o uso da RNA 32 para os casos da base de dados, agrupados pelo CEH.	134
Figura 21 – Diagrama de caixa (<i>boxplot</i>) para o erro percentual da predição de consumo com o uso de três redes neurais para os casos da base de dados com CEH superiores a 50.000.	139
Figura 22 – Diagrama de caixa (<i>boxplot</i>) para o erro percentual da predição de consumo com o uso de três redes neurais para os casos não vistos.	142
Figura 23 – Consumo predito versus consumo simulado para os casos não vistos (rede RNA29_sHIS - 14 neurônios de entrada, 29 neurônios na camada interna e 1 neurônio de saída).	143
Figura 24 – Diagrama de caixa (<i>boxplot</i>) para o erro percentual da predição de consumo com as redes neurais RNA 29_sHIS e RNA 40_geral, para Paraty e Bom Jesus da Lapa.	146
Figura 25 – Consumo predito versus consumo simulado – rede RNA29_sHIS.	147
Figura 26 – Consumo predito versus consumo simulado – rede RNA 40_geral.	148
Figura A1 - Variação do COP em função da temperatura externa do ar, para os <i>chillers</i> a ar utilizados na construção da base de dados.	180
Figura A2 - Variação do COP em função da carga parcial, para os <i>chillers</i> a ar utilizados na construção da base de dados.	181

Figura A3 - Variação do COP em função da carga parcial, para os <i>chillers</i> a água utilizados na construção da base de dados.	181
Figura B1 - Variação do COP em função da temperatura externa do ar, para os <i>chillers</i> a ar utilizados para gerar os casos não vistos.	185
Figura B2 - Variação do COP em função da carga parcial, para os <i>chillers</i> a ar utilizados para gerar os casos não vistos.	186
Figura B3 - Variação do COP em função da carga parcial, para os <i>chillers</i> a água utilizados para gerar os casos não vistos.	187
Figura D1 – Representação de uma RNA com 8 neurônios de entrada, 10 neurônios na camada interna e 1 neurônio de saída (Fonte: https://beckmw.wordpress.com/tag/nnet/).....	198

LISTA DE TABELAS

Tabela 1 – Valores críticos associados ao grau de confiança da amostra (Fonte: Versage, 2015).....	52
Tabela 2 - Relação entre etapas e resultados esperados.	68
Tabela 3 – Características dos <i>chillers</i> utilizados na análise de sensibilidade*.....	82
Tabela 4 – Arquivos climáticos empregados nas simulações.....	82
Tabela 5 – Variáveis utilizadas na análise de sensibilidade, e os seus respectivos valores.	83
Tabela 6 – Características do caso base.	96
Tabela 7 – Resultados de carga térmica, consumo e eficiência - caso base (Rio de Janeiro-RJ).	97
Tabela 8 – Resultados para CDH e carga térmica integrada anual de refrigeração para 20 cidades.....	99
Tabela 9 – Resultados de R^2 para a reta ajustada para relacionar carga térmica integrada anual de refrigeração e CDH com diferentes valores para temperatura base.....	101
Tabela 10 – Resultados de R^2 para a reta ajustada entre carga térmica integrada anual de refrigeração e CDH com diferentes valores para a entalpia base.	103
Tabela 11 – Cidades escolhidas para caracterizar a diversidade do clima brasileiro.....	108
Tabela 12 – Características das edificações nos 28 casos analisados..	109
Tabela 13 – Valores de erro padrão obtidos nas regressões lineares que relacionam a carga térmica integrada anual de refrigeração e os indicadores climáticos CDH, CDH_H e CEH.....	110
Tabela 14 – Índices de primeira ordem relacionando as variáveis de entrada e a carga térmica de refrigeração.....	112
Tabela 15 – Índices de primeira ordem relacionando as variáveis de entrada e o consumo de energia do sistema de climatização.....	114
Tabela 16 – Índices de ordem total relacionando as variáveis e a carga térmica de refrigeração.....	117
Tabela 17 – Índices de ordem total relacionando as variáveis e o consumo do sistema de climatização.....	118
Tabela 18 – Valores empregados para nove variáveis características.	121

Tabela 19 – Valores empregados para as 22 variáveis no processo de geração dos casos.....	122
Tabela 20 – Substituição das variáveis ciclo economizador/recuperador de calor e tipo de bombeamento de água gelada.....	127
Tabela 21 – Variáveis preditoras e variável de resposta - arquitetura inicial da RNA.....	128
Tabela 22 – Índices de desempenho das RNAs para diferentes tamanhos de amostra.....	131
Tabela 23 – Índices de desempenho das RNA com diferentes tamanhos de camada interna.....	132
Tabela 24 – Índices de desempenho da rede neural base e da rede neural RNA 40_geral.....	135
Tabela 25 – Índices de desempenho da rede neural base e das redes neurais treinadas separadamente para os casos com <i>chiller</i> a ar (RNA 32_ar) e a água (RNA 32_água).....	137
Tabela 26 – Índices de desempenho da rede neural base e da rede neural com substituição da variável preditora IPLV.....	137
Tabela 27 – Índices de desempenho da rede neural base e da rede neural sem o emprego do histograma da carga térmica como variável preditora.....	138
Tabela 28 – Valores empregados para as variáveis na criação dos casos não vistos.....	140
Tabela 29 – Arquivos climáticos utilizados para a criação dos casos não vistos.....	141
Tabela 30 – Índices de desempenho das redes neurais na predição do consumo anual do sistema de climatização nos casos não vistos.....	141
Tabela 31 – Índices de desempenho das redes neurais na predição do consumo anual do sistema de climatização em climas com distintos perfis de radiação solar.....	145
Tabela A1 - Características dos chillers utilizados para criar a base de dados.....	174
Tabela A2 - Características de referência dos <i>chillers</i> utilizados para criar a base de dados.....	175

Tabela A3 - Coeficientes da curva <i>ChillerCapFTemp</i> para os 25 <i>chillers</i> utilizados para criar a base de dados.	176
Tabela A4 - Coeficientes da curva <i>ChillerEIRFTemp</i> para os 25 <i>chillers</i> utilizados para criar a base de dados.	177
Tabela A5 - Faixas de temperatura para as quais as curvas <i>ChillerCapFTemp</i> e <i>ChillerEIRFTemp</i> são válidas.	178
Tabela A6 - Coeficientes da curva <i>ChillerEIRFPLR</i> para os 25 <i>chillers</i> utilizados para criar a base de dados, e faixas de PLR para as quais a curva é válida.	179
Tabela B1 - Características dos <i>chillers</i> utilizados para criar os casos não vistos.	183
Tabela B2 - Características de referência dos <i>chillers</i> utilizados para criar os casos não vistos.	183
Tabela B3 - Coeficientes da curva <i>ChillerCapFTemp</i> para os sete <i>chillers</i> utilizados para criar os casos não vistos.	184
Tabela B4 - Coeficientes da curva <i>ChillerEIRFTemp</i> para os sete <i>chillers</i> utilizados para criar os casos não vistos.	184
Tabela B5 - Faixas de temperatura para as quais as curvas <i>ChillerCapFTemp</i> e <i>ChillerEIRFTemp</i> são válidas.	184
Tabela B6 - Coeficientes da curva <i>ChillerEIRFPLR</i> para os sete <i>chillers</i> utilizados para criar os casos não vistos, e faixas de PLR para as quais a curva é válida.	185
Tabela D1 – Neurônios de entrada da RNA 29_sHIS, e valores do desvio padrão e da média na base de dados.	197
Tabela D2 - Coeficientes da rede neural artificial RNA 29_sHIS	199

SUMÁRIO

1.	INTRODUÇÃO	23
1.1.	OBJETIVOS.....	31
1.1.1.	OBJETIVO GERAL	31
1.1.2.	OBJETIVOS ESPECÍFICOS	31
	Os objetivos específicos desta tese são:	31
1.2.	ESTRUTURA.....	31
2.	REVISÃO BIBLIOGRÁFICA	33
2.1.	MÉTODOS PARA ESTIMAR O CONSUMO DE ENERGIA EM EDIFICAÇÕES.....	33
2.1.1.	Métodos de engenharia	34
2.1.2.	Métodos guiados por dados (<i>data-driven methods</i>)..	36
2.1.2.1.	Métodos de regressão.....	36
2.1.2.2.	Métodos de redes neurais artificiais (RNA).....	37
2.1.2.3.	Métodos de máquinas de vetores suporte (SVM)	41
2.1.3.	Métodos híbridos.....	42
2.1.4.	Desenvolvimento de metamodelos	46
2.1.4.1.	Seleção de parâmetros e valores relevantes.....	46
2.1.4.2.	Amostragem	48
2.1.4.3.	Treinamento do modelo.....	49
2.2.	CONSUMO DE ENERGIA DE SISTEMAS DE CLIMATIZAÇÃO	53
2.3.	CARACTERIZAÇÃO DO CLIMA EM MODELOS SIMPLIFICADOS	61
2.4.	CONSIDERAÇÕES FINAIS	65
3.	MÉTODO	67

3.1.	FASE I – CRIAÇÃO DA BASE DE DADOS	68
3.1.1.	Etapa 1 – Definição das variáveis	69
3.1.2.	Etapa 2 – Análise de sensibilidade	78
3.1.2.1.	Determinação dos valores das variáveis de entrada 78	
3.1.2.2.	Simulação de uma amostra	84
3.1.2.3.	Realização da análise de sensibilidade	85
3.1.3.	Etapa 3 – Amostragem pelo método Hipercubo Latino	85
3.1.4.	Etapa 4 – Simulações	86
3.2.	FASE II – DESENVOLVIMENTO DO METAMODELO .	87
3.2.1.	Etapa 5 – Pré-processamento	88
3.2.2.	Etapa 6 – Treinamento de modelos com diferentes tamanhos de amostra	90
3.2.3.	Etapa 7 – Aprimoramento do metamodelo	91
3.2.4.	Etapa 8 – Avaliação do metamodelo	93
4.	RESULTADOS E DISCUSSÕES	95
4.1.	DEFINIÇÃO DAS VARIÁVEIS	95
4.2.	ANÁLISE DE SENSIBILIDADE	111
4.3.	AMOSTRAGEM PELO MÉTODO HIPERCUBO LATINO 120	
4.4.	SIMULAÇÕES	124
4.5.	PRÉ-PROCESSAMENTO DOS DADOS	124
4.6.	TREINAMENTO DE MODELOS COM DIFERENTES TAMANHOS DE AMOSTRA	130
4.7.	APRIMORAMENTO DO METAMODELO	132
4.8.	AVALIAÇÃO DO METAMODELO	139

4.8.1.	Avaliação do metamodelo para casos não vistos ...	139
4.8.2.	Avaliação do metamodelo em climas com distintos perfis de radiação solar	144
5.	CONCLUSÕES	149
	REFERÊNCIAS	155
	ANEXO A – CHILLERS UTILIZADOS PARA CRIAR A BASE DE DADOS.....	171
	ANEXO B - CHILLERS UTILIZADOS PARA CRIAR OS CASOS NÃO VISTOS	183
	ANEXO C – MÉTODO SOBOL.....	189
	ANEXO D – COEFICIENTES DA REDE RNA 29_sHIS.....	197

1. INTRODUÇÃO

O rápido crescimento do consumo de energia no mundo tem levantado preocupações sobre as dificuldades de abastecimento, esgotamento dos recursos energéticos e dos graves impactos ambientais (destruição da camada de ozônio, aquecimento global, mudanças climáticas, entre outros). A contribuição das edificações (residenciais e comerciais) no consumo de energia tem atingido valores expressivos nos países desenvolvidos, excedendo o setor industrial e o setor de transporte. O consumo de energia das edificações nos Estados Unidos em 2016 representou 39,5% do consumo total do país, sendo que as edificações residenciais representaram 20,8% e as comerciais 18,7% (ANNUAL ENERGY OUTLOOK 2018). O crescimento da população, o aumento da demanda por edificações e dos níveis de conforto, juntamente com o aumento do tempo gasto pelos usuários no interior das edificações, asseguram que a tendência de crescimento da demanda irá continuar nos próximos anos (CHUA et al., 2013). Por estas razões, a eficiência energética em edificações é atualmente um dos principais objetivos das políticas energéticas dos países desenvolvidos e emergentes.

A participação das edificações residenciais, comerciais e públicas no consumo total de energia elétrica no Brasil também é elevada e apresenta um cenário de crescimento, considerando-se, sobretudo, a elevada taxa de urbanização e a expansão do setor de serviços (PROCEL, 2013). Em 2016, segundo o Relatório do Balanço Energético Nacional emitido pela Empresa de Pesquisa Energética - EPE, 51,0% da energia elétrica produzida no país foi utilizada na operação e manutenção das edificações (residenciais, comerciais e públicas) e na promoção de conforto aos seus usuários (EPE, 2017).

Segundo Pacheco et al. (2012), o desenvolvimento de projetos de edificações eficientes é uma prioridade nos países desenvolvidos e alguns critérios do projeto arquitetônico têm sido foco de estudos visando reduzir a demanda por aquecimento e resfriamento nas edificações, tais como: formato da edificação, orientação solar, materiais construtivos, elementos de sombreamento, ventilação natural e características técnicas dos vidros. Pode-se ressaltar ainda que a melhoria no projeto das edificações deve visar a redução do consumo de energia sem comprometer o nível de conforto proporcionado aos seus usuários. A eficiência energética de uma edificação envolve além das suas características construtivas, o dimensionamento de sistemas eficientes de climatização, iluminação, aquecimento de água, entre outros.

Regulamentos de eficiência energética em edificações e programas de certificação energética são ferramentas básicas para promover a eficiência energética neste setor. Regulamentos especificam requisitos mínimos para o projeto, construção e modernização (*retrofit*) de edifícios, enquanto que programas de certificação abrangem procedimentos que permitem a comparação qualitativa de edifícios em termos do seu uso de energia. Portanto, a certificação de energia de edificações está diretamente relacionada aos sistemas de classificação energética, programas de *benchmarking* e etiquetagem de edificações.

A presença de sistemas de climatização nas edificações tem se intensificado nos últimos anos devido ao aumento pela demanda de melhores condições de conforto térmico no interior das edificações. Sendo assim, o crescimento da utilização de energia pelos sistemas de climatização é particularmente significativo, representando nos países desenvolvidos o percentual de 50% do consumo das edificações, e 20% do consumo total de energia destes países (PÉREZ-LOMBARD et al., 2008). Portanto, grande parte da energia nos edifícios é utilizada para manter as condições de conforto internas, e nos edifícios comerciais este percentual representa quase 50%, e varia dependendo do clima (ENTERIA; MIZUTANI, 2011). Em 2016, os sistemas de climatização foram responsáveis por 40,4% do consumo nas edificações comerciais dos Estados Unidos (ANNUAL ENERGY OUTLOOK 2018). Em Hong Kong, o consumo dos sistemas de climatização representava cerca de 30% do consumo total das edificações comerciais em 2008 (LAM et al., 2010). E no Brasil, segundo a última pesquisa de posse e hábitos de consumo de energia realizada em 2005, o sistema de climatização representava em média 20% do total do consumo em residências, 47% no setor comercial alimentado por alta tensão, e 48% em edificações públicas (ELETROBRÁS, 2008).

De acordo com o estudo publicado pela *BSRIA World Air Conditioning* (2018), o mercado mundial de equipamentos de ar condicionado encontra-se em recuperação, depois de apresentar quedas nos valores das vendas de 5% em 2015 e de 1% em 2016 (BSRIA, 2017), causadas principalmente pela desaceleração econômica na China. Até 2014, o mercado vinha crescendo ano a ano, tendo crescido 7% em 2014 em relação à 2013 (BSRIA, 2015). Atualmente os grandes mercados, como os Estados Unidos, estão crescendo acima da média global, enquanto o mercado chinês está em recuperação, sendo esperados crescimentos de dois dígitos para os próximos anos. O rápido crescimento do emprego de sistemas de climatização é um fator agravante da crise ambiental e de energia no mundo. O uso de energia

para o resfriamento cresce mais rápido do que qualquer outro uso em edificações, ele triplicou entre 1990 e 2016, e poderá triplicar novamente até 2050 (IEA, 2018). A conservação de energia, o aumento da eficiência energética e o incentivo ao uso de fontes de energia renováveis são os três instrumentos principais utilizados para aliviar esta crise (PÉREZ-LOMBARD et al., 2011a).

O consumo dos sistemas de climatização representa uma parcela significativa no consumo global de uma edificação e pesquisas têm sido realizadas no sentido de identificar medidas de conservação de energia nestes sistemas. Um exemplo desta conduta é a pesquisa encomendada pelo governo dos Estados Unidos à empresa TIAX, que resultou no relatório *Energy Consumption Characteristics of Commercial Building HVAC Systems. Volume III: Energy Savings Potential* (ROTH et al., 2002). Neste relatório, os pesquisadores apresentam detalhadamente o potencial de economia de energia de 15 tecnologias empregadas em sistemas de climatização, diante de um universo de outras 40 tecnologias identificadas. Tais tecnologias são: controladores com lógica adaptativa/fuzzy, sistemas dedicados de ar externo, ventilação por deslocamento (*displacement ventilation*), motores de imã permanente comutados eletronicamente, recuperadores de calor para ventilação, *heat pump* para climas frios, melhorias na vedação de dutos, condicionadores de ar de dessecante líquido, trocador de calor de microcanais, controles baseados em ocupação/microambientes, novos métodos de termoacumulação, vigas e tetos frios, pequenos compressores centrífugos, diagnósticos de componentes/sistemas, e fluxo de refrigerante variável.

Os requisitos mínimos de eficiência dos sistemas de climatização presentes nos regulamentos de eficiência energética são fatores importantes para a promoção da eficiência energética das edificações. Pérez-Lombard et al. (2011b) apresentam uma ampla revisão destes requisitos para edificações comerciais, presentes em diversos regulamentos existentes ao redor do mundo (Estados Unidos, Canadá, Japão, China, Índia, Hong Kong, Austrália, Reino Unido, França e Espanha). Nestes regulamentos, em linhas gerais, os sistemas de climatização podem ser avaliados por um método prescritivo ou por um método de desempenho. O método prescritivo orienta os projetistas na seleção de componentes eficientes, estabelecendo um conjunto de requisitos mínimos nas seguintes categorias: eficiência mínima dos equipamentos, sistemas de distribuição de fluidos, sistemas de controle, renovação de ar, recuperadores de calor e economizadores. Vale ressaltar, no entanto, que o uso de equipamentos com elevada

classificação de eficiência energética, definida em função de condições padrões de teste, nem sempre proporciona o menor consumo de energia em condições reais de uso (MEISSNER et al., 2014). Buscando uma avaliação mais precisa, existe o método de desempenho, o qual consiste em verificar se o consumo do edifício proposto é inferior ao consumo de uma edificação de referência. Este método é mais adequado tanto para os projetistas, que tem maior liberdade na elaboração do projeto, quanto para as agências reguladoras que atingem seu objetivo de obter menor consumo nas edificações. No entanto, este método traz duas questões delicadas: como definir a edificação de referência e como estimar o consumo de energia. O artigo de Pérez-Lombard et al. (2011b) aborda com maior ênfase a primeira questão. A segunda questão será melhor abordada na sequência com o seguinte questionamento: como o consumo do sistema de climatização de uma edificação pode ser determinado?

A simulação energética de edificações é importante em estudos de desempenho, e em projetos e operação de edificações energeticamente eficientes. A simulação de edificações não somente revela as interações entre a edificação e seus ocupantes, sistemas de climatização e clima exterior, como também torna possível analisar opções de projeto que visam a conservação de energia (HONG et al., 2000). E nem sempre é possível dizer qual sistema de climatização é a melhor opção para uma determinada edificação sem a realização de uma simulação (KOROLIJA et al., 2013). No entanto, a simulação detalhada de uma edificação é usualmente complexa e requer a especificação de um grande número de parâmetros de entrada para realizar o cálculo do consumo, os quais nem sempre estão disponíveis nas fases iniciais de projeto. A complexidade das ferramentas de simulação existentes foi identificada por Ellis et al. (2001) como o maior obstáculo para a adoção mais ampla da simulação na prática, apesar do potencial que este método oferece.

De forma alternativa, os métodos simplificados, presentes nos regulamentos de eficiência energética, estimam o consumo do sistema de ar condicionado de uma edificação como a razão entre a energia necessária (resfriamento e aquecimento), obtida de cálculos de carga térmica, e as eficiências médias do sistema de climatização. Esta forma, aparentemente fácil, encobre o fato de que as eficiências são desconhecidas e que sua estimativa pode levar a imprecisões significativas nos resultados de consumo, embora algumas tabelas e correlações tenham sido desenvolvidas para auxiliar no processo de estimativa destas eficiências (PÉREZ-LOMBARD et al., 2011b).

No Brasil existe um programa de certificação energética de edificações comerciais (INMETRO, 2010) através do qual uma edificação comercial pode ser classificada de acordo com cinco possíveis níveis de eficiência (etiqueta de A – maior eficiência – até etiqueta E – menor eficiência). A avaliação pode ser realizada pelo método prescritivo ou pelo método de simulação. O método de simulação tem conceito similar ao método de desempenho por simulação presente nos regulamentos internacionais, descrito anteriormente. O método prescritivo é um método simplificado que emprega um metamodelo de equações de regressão linear múltipla para avaliação da envoltória, e requisitos mínimos para determinação do nível de eficiência do sistema de climatização e do sistema de iluminação. A adoção de eficiências mínimas para equipamentos, tais como: resfriadores de líquidos (*chillers*) e torres de resfriamento, pode falhar na avaliação global do sistema, visto que o consumo dos demais componentes do sistema (bombas e ventiladores, por exemplo) é bastante expressivo, e portanto não pode ser negligenciado.

O metamodelo para avaliação da envoltória, presente no método prescritivo do programa de certificação brasileiro, é resultado de pesquisas realizadas no LabEEE - Laboratório de Eficiência Energética em Edificações da Universidade Federal de Santa Catarina (UFSC). No desenvolvimento deste metamodelo, atualmente vigente, Carlo (2008) encontrou diversas limitações e recomendou que as equações obtidas fossem utilizadas somente para avaliar a envoltória através de um resultado entendido como Indicador de Consumo (IC), e não para estimar o real consumo de eletricidade da edificação. Uma destas limitações foi o emprego de um único tipo de sistema de climatização (condicionador de janela) em todas as simulações realizadas, mesmo tendo sido identificado o emprego de outros tipos de sistemas na amostragem realizada de edificações comerciais brasileiras. Os trabalhos desenvolvidos anteriormente no LabEEE, Signor (1999) e Westphal e Lamberts (2007), também empregaram um único tipo de sistema de climatização (condicionador de janela) para o desenvolvimento de equações para estimar o consumo de energia em edificações comerciais brasileiras. E mesmo recentemente, Melo (2012) ao propor um metamodelo com a aplicação de redes neurais artificiais, que se demonstrou mais preciso do que o modelo atual, ainda manteve a simplificação do emprego de um único tipo de sistema de climatização (condicionador tipo *split*).

Nesta linha de pesquisa do LabEEE, um novo metamodelo de rede neural artificial foi sugerido por Versage (2015). Neste metamodelo as

cargas térmicas integradas anuais de resfriamento e de aquecimento são obtidas para cada zona térmica, e as cargas térmicas integradas anuais globais da edificação podem ser determinadas pela ponderação em área que cada zona térmica representa na edificação. Portanto, o sistema de climatização não é modelado, e os resultados obtidos consistem na energia necessária para resfriamento e aquecimento, e não no consumo de energia da edificação.

Embora o desempenho térmico da envoltória (carga térmica) seja frequentemente utilizado na prática para avaliar o desempenho energético de uma edificação, ele não necessariamente reflete o consumo de energia da edificação em resposta a estas cargas térmicas (KOROLIJA et al., 2013). Para atender a mesma carga térmica, diferentes sistemas de climatização apresentam consumos distintos. Para ilustrar este fato, Korolija et al. (2011) realizaram simulações de edifícios de escritórios em Londres com dois tipos diferentes de sistema de climatização: água gelada com volume de ar variável (VAV) e ciclo economizador, e água gelada com *fancoil* e sistema dedicado de ar externo (DOAS). Os resultados mostraram que o sistema com ciclo economizador apresenta uma necessidade de energia térmica para resfriamento nos trocadores de calor até 40% menor do que a carga térmica da edificação, justificável pelo chamado *free cooling* proporcionado pelo ciclo economizador. O sistema sem ciclo economizador apresentou necessidade de energia térmica até 30% maior do que a carga térmica, justificado pelo acréscimo de calor gerado pelos ventiladores e bombas do sistema. Nesta mesma linha de estudo, Cho et al. (2014) simularam um edifício de escritórios na Coreia do Sul para gerar o consumo de energia de 33 sistemas básicos de climatização, e desenvolveram um método para prever o consumo de energia de 960 sistemas de climatização distintos (combinação de dezesseis tipos de sistemas de condicionamento de ar com 15 tipos de sistemas de transporte e quatro tipos de plantas de geração). Os resultados obtidos para os tipos distintos de condicionamento de ar revelaram que o conceito mais eficiente (vigas frias com sistema dedicado de ar externo) apresentou consumo 40% menor do que o conceito menos eficiente (climatizadores com vazão de ar constante), e para os quinze tipos de plantas de geração, o consumo do mais eficiente (*chiller* com compressor centrífugo) foi 33% menor do que o menos eficiente (*chiller* de absorção fogo direto).

O consumo de energia de um sistema de climatização não somente é influenciado pela escolha dos componentes do sistema, mas também pelo seu dimensionamento, o qual é afetado significativamente pelas

incertezas dos parâmetros utilizados no momento da estimativa da carga térmica da edificação. A aplicação defensiva de um fator de segurança, que é altamente dependente da experiência dos projetistas, pode facilmente levar ao superdimensionamento excessivo do sistema. Este assunto é discutido nos trabalhos de Djunaedy et al. (2011), Sun et al. (2014) e Gang et al.(2015).

Diante deste cenário, a busca pelo desenvolvimento de um método para determinação do consumo anual de energia de sistemas de climatização que não considera somente a carga térmica da edificação, mas também as características do sistema de climatização, se justifica como uma melhoria aos métodos simplificados existentes atualmente nos regulamentos de eficiência energética.

Este trabalho busca avançar no sentido de viabilizar a criação de um método de avaliação da eficiência energética de edifícios de escritórios que permita estimar o consumo destas edificações, através do desenvolvimento de um metamodelo capaz de estimar o consumo anual do sistema de climatização a partir do conhecimento da carga térmica integrada anual da edificação, do clima e das características do sistema de climatização. Desta forma, o novo método, baseado na estimativa do consumo, se caracteriza como um método simplificado de desempenho.

O consumo total de energia de uma edificação resulta da somatória do consumo do seu sistema de iluminação, dos equipamentos nela instalados, e do consumo do seu sistema de climatização. O consumo da iluminação e dos equipamentos pode ser estimado através do conhecimento das respectivas potências elétricas instaladas e dos perfis de uso. A estimativa do consumo do sistema de climatização é um processo bem mais complexo. Os sistemas de climatização são compostos por diversos equipamentos e componentes, que por sua vez, apresentam comportamento de consumo de energia diferenciado em função da carga térmica e das características climáticas a que estão submetidos.

Para viabilizar a proposta acima mencionada, esta tese busca responder ao seguinte questionamento: qual o melhor método para determinação simplificada do consumo anual do sistema de climatização de um edifício de escritórios para as características climáticas do Brasil a partir do conhecimento da carga térmica da edificação?

Os sistemas de climatização usualmente utilizados em edificações comerciais podem ser divididos em dois grupos: sistemas unitários de expansão direta (*splits* ambientes, *splits* dutados, *roof-top* e *self-contained*) empregados em edificações de pequeno e médio porte, e sistemas centrais (água gelada) em edificações de grande porte (YAN,

2014). O sistema de climatização caracterizado pelo uso de equipamentos individuais, condicionadores de janela e *splits*, é o mais encontrado nas edificações comerciais brasileiras, estando presente em 76,6% das edificações comerciais alimentadas por alta tensão e em 82% das edificações públicas. O sistema central de água gelada está presente em 16,2% das edificações comerciais alimentadas por alta tensão, e em 32% das edificações públicas (ELETROBRÁS, 2008).

Os sistemas centrais de água gelada mais eficientes usualmente apresentam coeficiente global de performance (COP) superior a 3,91 (0,9 kW/TR), podendo chegar a valores de COP global igual a 5,86 (0,6 kW/TR) com o emprego de novas tecnologias e estratégias, segundo Chua et al. (2013). E por apresentarem maior eficiência energética, quando comparados com os equipamentos individuais (condicionadores de janela e *splits*), tais sistemas de climatização serão foco deste trabalho.

Recentemente, uma revisão no atual regulamento brasileiro de etiquetagem de edificações comerciais (INMETRO, 2018) foi proposta e encontra-se em fase de desenvolvimento no INMETRO - Instituto Nacional de Metrologia, Normalização e Qualidade Industrial. Tal revisão propõe que o cálculo do consumo do sistema de climatização seja realizado dividindo-se a carga térmica total anual da edificação por uma eficiência global do sistema de climatização em carga parcial (*SPLV - System Part-Load Value*). Tal eficiência considera a região climática, as horas de operação ao longo do dia, a tipologia da edificação e o tipo de sistema de condicionamento de ar. As planilhas de cálculo desta eficiência ainda não estavam disponíveis até a data de redação desta tese, não permitindo assim que uma análise criteriosa do método fosse realizada.

É importante ressaltar que o metamodelo aqui proposto permitirá estimar o consumo anual do sistema de climatização de uma forma mais precisa e simplificada, a partir da carga térmica integrada anual da edificação, do clima, e dos dados característicos do sistema, avaliando o impacto de medidas de conservação de energia impostas ao sistema de climatização quando associado à edificação em estudo. Somente o consumo de resfriamento será considerado, pois o consumo de aquecimento é insignificante nas edificações comerciais brasileiras.

A seguir serão apresentados os objetivos do trabalho.

1.1. OBJETIVOS

1.1.1. OBJETIVO GERAL

O objetivo desta tese é desenvolver um metamodelo para determinação do consumo anual de energia de sistemas de ar condicionado do tipo água gelada em edifícios de escritórios em diferentes climas.

1.1.2. OBJETIVOS ESPECÍFICOS

Os objetivos específicos desta tese são:

- Identificar quais as características da edificação e do sistema de climatização que apresentam maior e menor influência sobre os resultados de carga térmica integrada anual de resfriamento e de consumo de energia do sistema de climatização;
- Analisar o desempenho do uso de indicadores climáticos para caracterizar o clima, buscando desenvolver novos indicadores, se necessário;
- Avaliar e definir qual a arquitetura do metamodelo que apresenta melhor desempenho ao prever o consumo de sistemas de climatização.

1.2. ESTRUTURA

A presente tese é composta de cinco capítulos. O primeiro capítulo apresenta as justificativas e os objetivos da tese. O capítulo 2 apresenta uma revisão bibliográfica sobre os assuntos que contextualizam os estudos desenvolvidos nesta tese. Em seguida, o método é descrito no capítulo 3, esclarecendo as etapas que foram utilizadas para atingir os objetivos propostos. No capítulo 4 são apresentados e discutidos os resultados obtidos, e no capítulo 5 são apresentadas as conclusões.

2. REVISÃO BIBLIOGRÁFICA

Este capítulo descreve os resultados obtidos durante a revisão bibliográfica, a qual teve como finalidade estabelecer o referencial teórico que constituirá a base de sustentação desta pesquisa científica.

Para o levantamento dos trabalhos realizados sobre o tema em questão foram realizadas buscas por publicações sobre predição do consumo de energia de sistema de climatização em edificações nas bases de dados Scopus, Ebsco, Wiley, Compendex – Engineering Village e Emerald, considerando a combinação das palavras-chaves *building+consumption+air*, *conditioning+prediction*, ou *building+consumption+HVAC+prediction*, ou *building+consumption+air* *conditioning+predict*, ou *building+consumption+HVAC+predict*. Estes termos foram buscados em títulos, resumos e palavras-chave. O programa Endnote X5 foi utilizado para armazenamento e organização dos trabalhos encontrados. Com a leitura dos títulos e resumos, foram selecionados os artigos que compuseram a base inicial da revisão bibliográfica. A leitura integral destes artigos permitiu identificar outros artigos neles referenciados, que também foram obtidos e lidos. Foram incluídas também as teses já desenvolvidas no LabEEE sobre o assunto.

A partir da leitura dos artigos e teses o presente capítulo foi estruturado por meio de três tópicos: métodos para estimar o consumo de energia em edificações, consumo de energia de sistemas de climatização, e caracterização do clima em modelos simplificados. O primeiro tópico descreve os diferentes métodos empregados para estimar o consumo de edificações, demonstrando que o método híbrido é uma escolha adequada para o desenvolvimento do presente trabalho. O segundo tópico revela a dificuldade existente na determinação do consumo de energia dos sistemas de climatização, que tem o método de simulação como solução mais precisa, mas tem carência de modelos simplificados eficazes. O terceiro tópico apresenta os indicadores climáticos que são usualmente empregados para caracterizar o clima em modelos simplificados. A seguir são apresentados estes três tópicos.

2.1. MÉTODOS PARA ESTIMAR O CONSUMO DE ENERGIA EM EDIFICAÇÕES

O desempenho energético de edificações é influenciado por diversos fatores, tais como condições climáticas, características construtivas da edificação, atributos e operação dos sistemas de iluminação e climatização, perfil de ocupação e comportamento dos usuários. Esta situação complexa torna muito difícil prever com precisão o consumo de

energia de uma edificação. Nos últimos anos, uma grande quantidade de métodos para predição do consumo, tanto elaborados quanto simplificados, foi proposta e aplicada no projeto, operação e modernização (*retrofit*) de edificações. Os trabalhos recentes de Wei et al. (2018); Fumo (2014); Fouquier et al. (2013) e Zhao e Magoulès (2012), buscaram classificar os métodos utilizados por pesquisadores para prever o desempenho energético de edificações, bem como identificar as peculiaridades de cada método e referenciar exemplos de aplicação.

Os métodos empregados para estimar o consumo de energia em edificações podem ser divididos em três categorias: métodos de engenharia, métodos guiados por dados (*data-driven methods*) e métodos híbridos. Uma descrição das características de cada um destes métodos é apresentada a seguir.

2.1.1. Métodos de engenharia

Os métodos de engenharia, ou métodos físicos, usam modelagem dos princípios físicos para calcular o comportamento térmico e o desempenho energético da edificação como um todo, ou de seus sistemas isoladamente. E por este motivo, são conhecidos também como métodos caixa branca (“*white box*”). Há tanto métodos detalhados quanto métodos simplificados.

Os métodos detalhados utilizam modelos matemáticos que representam o comportamento físico da edificação e de seus sistemas, para calcular precisamente, a cada intervalo de tempo, o consumo energético de todos os componentes da edificação a partir das informações que caracterizam a edificação (envoltória e sistemas), o seu uso, e o clima do local. Diversas ferramentas computacionais têm sido desenvolvidas com a aplicação deste tipo de método, que caracteriza a simulação de edificações (*building energy simulation*), tais como DOE-2, EnergyPlus, BLAST, ESP-r e TRNSYS, entre outras. Uma revisão do desenvolvimento histórico e aplicação das principais ferramentas de simulação foi apresentada por Hong et al. (2000), e ilustra como este método é importante no estudo do desempenho energético na fase de projeto e na fase de operação de edificações eficientes.

Embora estas ferramentas de simulação sejam eficazes e mais precisas, na prática, existem algumas dificuldades. Por serem baseadas em princípios físicos, necessitam de muitos parâmetros detalhados da edificação, dos sistemas e do clima, para realizarem uma simulação com precisão. E, geralmente, estes parâmetros não estão disponíveis e/ou são de difícil obtenção. Outro aspecto que limita o emprego destas

ferramentas é que normalmente exigem um trabalho árduo de profissionais com alta experiência, tornando a execução difícil e onerosa. Por esta razão, métodos simplificados têm sido propostos como alternativa. Al-Homoud (2001) descreve os dois métodos simplificados mais conhecidos: o método graus-dia e o método bin.

O método graus-dia é adequado para estimar a energia requerida para aquecimento ou resfriamento em pequenas edificações, e apresenta as seguintes deficiências:

- os ganhos internos de calor não são considerados de forma precisa;
- a aplicação restringe-se às edificações onde os fatores dominantes na carga térmica são a transmissão de calor através da envoltória e a infiltração de ar;
- os resultados são conservadores, melhores níveis de isolamento e aumento de cargas internas podem gerar valores superestimados;
- o método se baseia em condições médias, não considerando as variações climáticas ao longo do dia.

O método graus-dia tem sido mais empregado para estimar o consumo anual de aquecimento em edificações residenciais. O uso do método graus-dia não é adequado nas edificações onde os ganhos internos são significativos, ou onde as cargas de resfriamento não apresentam comportamento linear com a diferença de temperatura externa/interna, tais como edificações comerciais de grande porte. Efeitos de inércia térmica, da umidade, da radiação solar, da eficiência dos equipamentos, e do desempenho em carga parcial, não são captados pelo método graus-dia.

O método bin, ou método de distribuição de frequências de temperatura, consiste em realizar os cálculos de energia térmica de aquecimento e resfriamento para diferentes condições de temperatura externa (bins), e multiplicar os resultados pelo número de horas que ocorre em cada condição (bin). Este método se caracteriza por:

- calcular cargas de aquecimento e resfriamento;
- calcular cargas de ventilação e infiltração utilizando a temperatura média de bulbo úmido para cada bin;
- considerar condições de ocupação da edificação e de cargas internas;
- ser útil para análise de equipamentos individuais;
- permitir a avaliação do desempenho de sistemas de climatização em carga parcial;

- considerar a variação horária das condições climáticas.

O método bin apresenta resultados razoáveis para edificações de baixa massa e carga interna dominante, mas deve ser utilizado com cautela quando os efeitos da radiação solar e de inércia térmica são dominantes (HUNN, 1996).

Outro método simplificado é o método Rede Resistor-Capacitor, que consiste em descrever as transferências de calor entre o ambiente externo e o ambiente interno de uma edificação fazendo analogia ao circuito elétrico. O princípio desta analogia é associar resistências térmicas e capacitâncias térmicas para modelar os processos de transferência de calor envolvidos. Assim, o problema físico é simplificado drasticamente através da linearização das equações, e o tempo computacional é reduzido. Vários artigos utilizando esta analogia têm sido publicados, tais como os trabalhos de Braun e Chaturvedi (2002), Wang e Xu (2006), O'Neill et al. (2010), Li e Huang (2013).

Observa-se, portanto, que os métodos de engenharia sempre necessitam de uma formulação dos processos físicos envolvidos e de informações das características da edificação, dos sistemas e do clima. De forma distinta, os métodos guiados por dados permitem a construção de um modelo a partir somente de dados de desempenho obtidos através de medições. A seguir são descritas as características dos métodos guiados por dados usualmente empregados em análises de energia em edificações.

2.1.2. Métodos guiados por dados (*data-driven methods*)

Os métodos guiados por dados não necessitam de nenhuma informação dos processos físicos. Nenhuma equação de transferência de calor, propriedade térmica ou geométrica da edificação é necessária. Os métodos guiados por dados são baseados na implementação de uma função deduzida apenas de amostras de dados que descrevem o comportamento de um sistema específico. Por estas razões, são também chamados de métodos caixa preta ("*black box*").

Na sequência são descritas as principais técnicas utilizadas para criar modelos que estimam o consumo de energia em edificações: análise de regressão, redes neurais artificiais e máquinas de vetores suporte. Sendo que estas duas últimas são técnicas de inteligência artificial.

2.1.2.1. Métodos de regressão

Modelos estatísticos que utilizam análise de regressão simplesmente correlacionam o consumo de energia, ou índice de energia, com as variáveis de influência. Análise de regressão é uma das técnicas mais

populares para o desenvolvimento de modelos de predição (TSO et al., 2007). Quando as equações de regressão são obtidas a partir de um conjunto preciso e completo de dados, elas podem providenciar resultados precisos de uma forma mais fácil e rápida do que utilizando ferramentas de simulação de edificações (FREIRE et al., 2008). Um modelo de regressão multivariada pode ser escrito conforme a Equação 1.

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_px_p + \varepsilon \quad (1)$$

Onde:

y é a variável de saída;

β_i são os coeficientes da regressão ($i=0,1,2,\dots,p$);

x_i são as variáveis de entrada ($i=1,2,\dots,p$);

ε é o termo de erro aleatório.

Estes modelos empíricos são desenvolvidos a partir de dados históricos de desempenho, e o método de mínimos quadrados é geralmente utilizado para obtenção dos coeficientes da regressão. A popularidade dos modelos de regressão pode ser atribuída à facilidade de interpretação dos parâmetros do modelo e à facilidade de uso. No entanto, a maior limitação deste método é sua incapacidade para tratar problemas não lineares.

No setor de edificações, os modelos de regressão são utilizados frequentemente para prever o consumo de energia, ou comparar a evolução da demanda de energia entre dois períodos de tempo distintos. Uma grande quantidade de dados é necessária para uma adequada predição, bem como uma não colinearidade entre as variáveis independentes.

2.1.2.2. Métodos de redes neurais artificiais (RNA)

O conceito de análise de rede neural foi desenvolvido há cerca de 60 anos atrás, mas somente nos últimos 30 anos ferramentas computacionais foram desenvolvidas para utilizá-lo na solução de problemas práticos. As redes neurais artificiais têm sido aplicadas com sucesso em vários campos da matemática, engenharia, medicina, economia, meteorologia, psicologia, neurologia e reconhecimento de fala, na identificação de alvos militares e na identificação de explosivos em malas de passageiros. Elas também têm sido usadas nas previsões do clima e tendências de mercado, na predição de locais de exploração mineral, na predição de cargas térmicas e elétricas, no controle robótico e adaptativo (KALOGIROU, 2001).

As redes neurais têm sido empregadas também em uma ampla gama de problemas de energia em engenharia, sendo o método guiado por

dados mais empregado atualmente nos modelos de predição de energia em edificações (DONG et al.,2018).

Zhao e Magoulès (2012) constataram que nos últimos vinte anos pesquisadores têm aplicado redes neurais artificiais para analisar vários tipos de consumo de energia em edificações, em uma variedade de condições, tais como: carga térmica de aquecimento e resfriamento, consumo de eletricidade, operação e otimização de sistemas, estimativa de parâmetros de utilização.

Wang et al. (2017) revisaram artigos publicados com o emprego de inteligência artificial na predição de energia de edificações entre os anos de 2011 e 2016, e identificaram que 26% empregaram regressão múltipla linear, 41% redes neurais artificiais, 12% máquinas de vetor suporte, e 21% outros métodos (tais como: *ARMAX-Autoregressive Moving Average with Exogenous inputs*, *CR-Case-based Reasoning*, *CHAID-CHI-squared Automatic Interaction Detection*, entre outros)

As redes neurais artificiais são amplamente empregadas devido a sua facilidade de implementação e ao seu desempenho confiável, bem como sua eficácia na solução de problemas não lineares e complexos.

As redes neurais modelam relações funcionais entre os dados de entrada e de saída, e podem fazer previsões a respeito de combinações distintas de dados de entrada. As redes neurais têm o potencial de fazer melhores previsões, mais rapidamente e de forma mais prática, do que qualquer método tradicional (KALOGIROU, 2006).

As redes neurais artificiais são compostas de elementos simples, inspirados no sistema nervoso humano, e que operam em paralelo. Um diagrama esquemático da arquitetura de rede neural de multicamada é apresentado na Figura 1. Neste diagrama são ilustradas duas camadas internas de neurônios, mas o número de camadas internas pode ser maior ou menor, dependendo do problema abordado. De forma simples, cada neurônio é conectado a todos os outros neurônios da camada anterior através de pesos sinápticos. O número de parâmetros de entrada e saída, e o número de camadas internas, influenciam na geometria da rede. A rede consiste de uma camada de neurônios de entrada, com um neurônio correspondendo a cada parâmetro de entrada, uma ou mais camadas internas de neurônios, e uma camada de neurônios de saída, sendo um neurônio para cada saída. Um neurônio é a unidade básica de uma rede neural e executa funções de ativação e adição para determinar a saída desse neurônio. O número de camadas internas é aproximadamente a média entre o número de entradas e saídas, embora dependa também do número de casos utilizados no treinamento da rede. Três tipos de parâmetros são tipicamente usados para definir as redes

neurais: o padrão de interconectividade entre os neurônios de diferentes camadas, o processo de aprendizado para atualizar os pesos sinápticos, e a função ativação que converte uma entrada ponderada de um neurônio em sua ativação de saída.

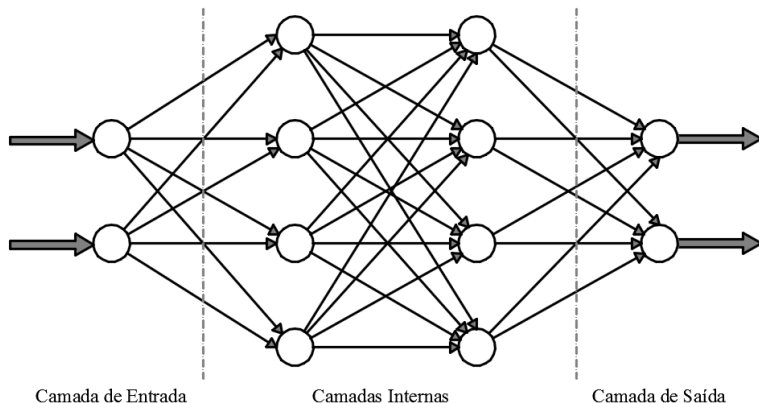


Figura 1 - Diagrama esquemático de uma rede neural multicamada.

O treinamento da rede neural artificial consiste usualmente na adaptação adequada dos pesos sinápticos que melhor represente o padrão de comportamento apresentado por uma amostra com dados de entrada e saída correspondentes. O processo de treinamento começa com um conjunto de pesos sinápticos aleatórios gerando saídas a partir de cada conjunto de dados de entrada. A cada conjunto de saídas da rede neural, os valores gerados são comparados com os valores corretos disponíveis na amostra, e havendo diferença, os pesos sinápticos são alterados na direção de reduzir o erro. Se o erro ainda estiver superior à tolerância máxima desejada após rodar todos os conjuntos de dados de entrada, a rede passa novamente através de todos os conjuntos de dados de entrada repetidamente até que todos os erros estejam dentro da tolerância desejada. Quando o treinamento atinge um nível satisfatório, os pesos sinápticos da rede são tornados constantes e a rede treinada pode ser empregada para tomar decisões, identificar padrões ou definir associações em um novo conjunto de dados de entrada, não utilizados no treinamento.

Os algoritmos de aprendizado mais utilizados e poderosos no treinamento de redes neurais são os de retropropagação e suas variantes (KUMAR et al., 2013). A maioria dos sistemas de aprendizado das redes neurais utiliza alguma forma de algoritmo de retropropagação (FAHLMAN, 1988). Este tipo de algoritmo tenta melhorar o

desempenho da rede neural pela redução do erro total através da mudança dos pesos sinápticos ao longo do seu gradiente. Maiores detalhes do algoritmo de retropropagação podem ser encontrados no trabalho de Kalogirou (2000).

O procedimento básico a ser seguido para resolver problemas com o uso de redes neurais artificiais é selecionar de forma adequada a arquitetura, a taxa de aprendizagem, o número de camadas de neurônios internos e as funções de ativação. Este é um método trabalhoso e demorado, mas que através da experiência já acumulada permite definir alguns parâmetros facilmente, reduzindo significativamente o tempo necessário (KALOGIROU, 2001).

O emprego de redes neurais artificiais para estimar o uso da energia em edificações tem sido investigado nas últimas duas décadas. Uma revisão deste assunto pode ser encontrada em Kumar et al. (2013), onde são citados trabalhos que empregam redes neurais artificiais para estimar as cargas térmicas de resfriamento e aquecimento, para prever o consumo de energia, e para otimizar o funcionamento de sistemas de climatização. Estes autores afirmaram que o uso de redes neurais artificiais treinadas por retropropagação é melhor para avaliar, estimar e prever um conjunto de grande quantidade de dados, do que qualquer método estatístico. Por exemplo, os erros percentuais médios obtidos com retropropagação são sempre menores que os erros percentuais médios obtidos com o uso do método de mínimos quadrados.

Wang et al. (2017), ao revisarem o emprego de inteligência artificial na predição de energia em edificações, constataram que a maior vantagem das redes neurais artificiais é sua habilidade de detectar relações não-lineares complexas entre as entradas e saídas, e que as pesquisas indicam que as redes neurais artificiais apresentam desempenho superior aos modelos de regressão. Estes autores dividiram os trabalhos que empregavam redes neurais artificiais em quatro grupos com relação ao objetivo: predição de consumo global em edificações, carga térmica de aquecimento, carga térmica de resfriamento, e consumo de eletricidade. A seguir são relacionados exemplos de cada um destes grupos. Li et al. (2011) utilizaram redes neurais e um método híbrido (GA-ANFIS) para prever o consumo global de uma edificação. Ekici and Aksoy (2009) utilizaram RNAs para prever a carga térmica de aquecimento de três edifícios para diferentes orientações solares, espessuras de isolamento térmico e percentual de abertura nas fachadas; e os resultados preditos, quando comparados com resultados calculados numericamente, obtiveram precisão média de 94,8 a 98,5%. Yokoyama et al. (2009) utilizaram RNAs para prever a carga térmica de

resfriamento de uma edificação empregando um método de otimização (*Modal Trimming Method*) para identificar os parâmetros do modelo e melhorar o desempenho da predição. E os trabalhos de Platon et al. (2015), Chae et al. (2016) e Mena et al. (2014) empregaram RNAs na predição de consumo de eletricidade em edificações. Planton et al. (2015) utilizaram duas técnicas de inteligência artificial, RNA e CBR (*case-based reasoning*), obtendo erros menores com a RNA. Os resultados do modelo proposto por Chae et al. (2016) demonstraram que tal modelo é capaz de prever razoavelmente bem o consumo de eletricidade com intervalos de 15 minutos e o pico de demanda diário de um edifício comercial complexo. Os experimentos realizados por Mena et al. (2014), para predição do consumo de eletricidade de uma edificação bioclimática, mostraram resultados adequados para um horizonte de predição de curto prazo (60 minutos), com erro médio de 11,48%.

As redes neurais artificiais, devido a sua capacidade de treinamento a partir dos dados, tem a habilidade de deduzir as relações entre as diferentes variáveis, sem nenhuma suposição ou postulado a respeito do modelo. As redes neurais também permitem uma grande variedade no formato das variáveis (sim/não, valor binário, valor contínuo, entre outras) e apresentam um eficiente tempo de treinamento. No entanto, assim como os modelos de regressão, necessitam de uma amostra relevante de dados, completa e representativa.

2.1.2.3. Métodos de máquinas de vetores suporte (SVM)

As máquinas de vetores suporte são algoritmos de aprendizagem que têm a capacidade de resolver problemas de classificação e regressão, adquirindo na etapa de treinamento, a capacidade de reconhecer padrões. Os métodos de máquinas de vetores suporte são altamente eficazes na solução de problemas não-lineares, mesmo com pouca quantidade de dados para treinamento, sendo que a principal dificuldade nas SVM é o ajuste de parâmetros necessários na modelagem (tipo de função kernel e os parâmetros da função escolhida, constante de regularização, entre outros). O seu emprego para prever consumo de energia em edificações é recente conforme descrito e exemplificado no trabalho de Fouquier et al. (2013), os quais mencionam Dong et al. (2005) como os precursores.

Na área de edificações, os métodos SVM são utilizados principalmente no desenvolvimento de modelo de predição de consumo de energia elétrica. O modelo pode ser treinado por diferentes tipos de dados com várias escalas de tempo (ano, mês, hora) e várias naturezas

(instantâneo ou valor médio). Uma grande vantagem é o fato de que o treinamento pode ser realizado a partir de uma base de dados heterogênea, onde todas as variáveis não possuem a mesma quantidade de informações ou podem apresentar falta de dados. No entanto, os métodos SVM têm baixa eficiência de cálculo, especialmente para análise energética de edificações de larga escala, e para reduzir o tempo de processamento, esforços têm sido feitos recentemente no sentido de desenvolver formas para otimizar sua eficiência computacional (WEI et al., 2018).

Uma análise entre os métodos guiados por dados permite concluir que o método de regressão multivariada é o método mais fácil, capaz de gerar uma boa predição sem necessitar de um grande conhecimento para sua implementação. No entanto, apresenta a limitação de assumir uma descrição linear para o fenômeno. Ao contrário, os métodos de RNA são capazes de tratar com problemas lineares e não-lineares, mas necessitam de uma quantidade maior de dados para treinamento. Os métodos de SVM têm a vantagem de não necessitarem de dados completos, mas diferente dos RNA, precisam de definições na modelagem (função kernel). Sendo assim a escolha do método depende principalmente do usuário e do que se espera obter.

2.1.3. Métodos híbridos

As características, vantagens e desvantagens dos métodos de engenharia e dos métodos guiados por dados foram apresentadas nos itens anteriores. Os métodos de engenharia assumem que todas as características da edificação são totalmente conhecidas, e que os fenômenos físicos envolvidos são modelados com alta precisão, o que nem sempre é possível obter. Os métodos guiados por dados estão limitados ao fato de necessitarem de amostra de dados, geralmente em grande quantidade, e que o modelo gerado a partir dos dados de uma edificação específica é válido somente para aquela edificação. Para tentar superar as limitações destes dois métodos existem os métodos híbridos, que são combinações de métodos de engenharia com métodos guiados por dados. Os métodos híbridos também são chamados de métodos caixa cinza (“*grey box*”).

Na área de edificações, existem três estratégias de acoplamento entre os métodos de engenharia e os métodos guiados por dados para obtenção de um método híbrido. A primeira estratégia consiste em usar um método guiado por dados de aprendizagem para estimar parâmetros físicos. A segunda estratégia é usar métodos guiados por dados (regressão, RNA ou SVM) para implementar um modelo a partir de uma

base de dados gerados a partir do uso de métodos de engenharia. E a terceira estratégia consiste em usar um método guiado por dados em partes onde modelos físicos não apresentam adequada precisão e eficácia. A seguir são apresentados exemplos do emprego da segunda estratégia.

Sander et al. (1993) desenvolveram modelos simplificados por regressão para prever a alteração no consumo de energia de aquecimento e resfriamento devido à alteração das características térmicas da envoltória. Os dados para o desenvolvimento dos modelos foram obtidos com a simulação de 5.400 casos, onde os valores de transmissão de calor, ganhos solares e ganhos internos, foram parametrizados para uma edificação dotada de um sistema de climatização do tipo água gelada com VAV (volume de ar variável) em 25 cidades do Canadá.

De forma semelhante, 387 simulações paramétricas de um edifício genérico de escritórios, com um sistema de climatização do tipo água gelada em Hong Kong, foram realizadas por Lam et al. (1997) para desenvolver três modelos de predição por regressão: carga térmica de resfriamento, consumo de energia do sistema secundário de climatização (climatizadores) e o consumo de energia do sistema primário (central de água gelada). Posteriormente, Lam et al. (2010) estenderam este mesmo estudo, desenvolvendo modelos de predição de consumo de energia para um edifício genérico de escritórios em cinco diferentes climas da China.

Por meio de simulações e análise de regressão, Lee et al. (2001) desenvolveram um método simplificado para estimar o consumo e a máxima demanda elétrica do sistema de climatização central (água gelada) em edifícios de escritórios existentes em Hong Kong. Na equação do consumo foram utilizadas como variáveis independentes: a carga térmica anual de refrigeração, o coeficiente de performance (COP) do *chiller*, a potência elétrica instalada das bombas e dos ventiladores.

Ben-Nakhi e Mahmoud (2004) utilizaram redes neurais artificiais para prever a carga térmica de edifícios de escritórios no Kuwait com o objetivo de otimizar o processo de termoacumulação em sistemas de climatização. Um software de simulação de edificações (ESP-r) foi utilizado para gerar uma base de dados de carga térmica para três edificações com base nos dados climáticos de anos anteriores. Esta base de dados foi utilizada para treinar a rede neural que teve como função prever o perfil de carga térmica para situações climáticas futuras.

Um método por regressão simplificado para prever o impacto do formato de um edifício de escritórios no consumo anual de energia foi desenvolvido por Ourghi et al. (2006), com base na realização de simulações combinando diferentes geometrias de envoltória, tipos de

vidro, áreas das janelas e clima. O sistema de ar condicionado modelado foi o de expansão direta com volume de ar variável (VAV).

As equações do índice Indicador de Consumo, utilizadas para a avaliação do desempenho da envoltória de edificações comerciais no método prescritivo do regulamento brasileiro de eficiência energética, foram desenvolvidas através do método estatístico de análise de regressão multivariada (CARLO e LAMBERTS, 2008), onde os dados para o ajuste das equações foram obtidos através de simulação de edificações. Da mesma forma, Zhou e Zhu (2013) desenvolveram um modelo de regressão para quatro climas típicos da China com o objetivo de avaliar a influência de oito fatores da envoltória no consumo de energia do sistema de climatização de edifícios de escritórios.

Catalina (2012) desenvolveu um método simplificado para estimar a carga térmica integrada de aquecimento de edificações residenciais, para ser empregado durante as fases de projeto ou modernização. Trata-se de um modelo de regressão multivariada desenvolvido a partir de dados gerados por 8.478 simulações com o software TRNSYS. Foi utilizada uma eficiência média para o sistema de aquecimento com o objetivo de estimar o consumo.

Xu et al. (2012) geraram uma base de dados como uso do software EnergyPlus para treinar uma rede neural artificial com o intuito de prever o consumo de energia em edificações residenciais. Neste trabalho eles buscaram avaliar o impacto mútuo entre as edificações vizinhas e o comportamento de seus ocupantes, quantificando o potencial de conservação de energia a ser obtida pelo *retrofit* destas edificações.

Korolija et al. (2013) apresentam em seu artigo modelos por regressão para prever a energia anual requerida para aquecimento e resfriamento, para cinco diferentes sistemas de climatização, como uma função somente das cargas térmicas anuais de aquecimento e resfriamento de edifícios de escritórios. Para representar os edifícios de escritórios existentes no Reino Unido, parâmetros que caracterizam as edificações foram combinados, resultando em 3.840 modelos de edificações, os quais por sua vez foram combinados com 5 tipos diferentes de sistemas de climatização. O total de 23.040 cenários possíveis foi criado e simulado utilizando o software Energyplus. Os sistemas de climatização analisados foram: volume de ar variável (VAV), volume de ar constante (CAV), *fancoil* com sistema dedicado de ar externo, sistema de resfriamento com teto radiante (tubos embutidos) e aquecimento por radiadores, e sistema de resfriamento com teto radiante (painéis de alumínio) e aquecimento por radiadores. Em todos os sistemas não foi modelado o sistema primário (*chiller* e o

boiler), sendo modelados a energia utilizada para resfriamento/aquecimento e o consumo do sistema secundário de climatização (bombas, ventiladores e controles). Somente o clima de Londres foi considerado, e alguns parâmetros da edificação e dos sistemas de climatização foram fixados, limitando assim a utilização dos modelos.

No Brasil, os pesquisadores do LabEEE/UFSC continuaram desenvolvendo modelos híbridos para avaliar o desempenho energético de edificações. Conforme já mencionado no capítulo anterior, Melo (2012) propôs um metamodelo com a aplicação de redes neurais artificiais para determinar um índice de consumo de edificações comerciais, a partir de uma base de dados gerados através de simulação. Foram simulados 3.200 casos, através do software Energyplus, dos quais 50% foram utilizados para treinar, 25% para validar e 25% para verificar o desempenho da rede neural. O emprego de redes neurais artificiais, quando comparado com análise de regressão, reduziu o erro médio na avaliação do consumo, melhorando a precisão e a eficiência do método. E da mesma forma, Versage (2015) realizou simulações para obter dados para treinar uma rede neural artificial capaz de estimar as cargas térmicas anuais de resfriamento e de aquecimento para uma zona térmica.

Recentemente, Dong et al. (2018) utilizaram redes neurais artificiais, treinadas a partir de resultados de simulações, para prever o consumo total de energia e o custo de edifícios de escritórios do tipo *cross laminated timber (CLT)* em regiões de clima de frio intenso, na fase inicial do projeto arquitetônico. Os resultados indicaram que o tempo para realizar estas previsões com o uso de redes neurais artificiais foi 80% menor do que o método tradicional (simulação + método de cálculo de custo).

A revisão bibliográfica mostrou que existem três grupos de métodos utilizados para estimar o consumo de energia em edificações: métodos de engenharia, métodos guiados por dados e métodos híbridos. Há trabalhos com o emprego dos diferentes métodos, e dentre os que buscam desenvolver modelos simplificados, ênfase tem sido dada ao comportamento térmico da edificação (estimativa da carga térmica integrada anual de resfriamento ou aquecimento), e poucos trabalhos tem buscado estimar o consumo global do sistema de climatização.

Avanços significativos têm sido obtidos nas últimas décadas na redução do consumo de sistemas de climatização com a aplicação de técnicas de inteligência artificial no projeto, controle, gerenciamento,

otimização, detecção e diagnóstico de falhas destes sistemas (AHMAD et al., 2016).

Diante deste cenário, o presente trabalho desenvolveu um metamodelo, que se caracteriza como um método híbrido, pois utiliza redes neurais artificiais, treinadas a partir de uma base de dados obtida através da realização de simulações de edificações.

2.1.4. Desenvolvimento de metamodelos

O processo de desenvolvimento de um metamodelo é composto por três principais etapas: 1) Seleção de parâmetros e valores relevantes, 2) Amostragem de um conjunto representativo, e 3) Treinamento do modelo (VERSAGE, 2015). A seguir são descritos métodos utilizados nestas três etapas.

2.1.4.1. Seleção de parâmetros e valores relevantes

O número de parâmetros tem um impacto no número de experimentos necessários (simulações computacionais, no presente caso), portanto é necessário minimizá-lo (FORRESTER et al., 2008). Análise de sensibilidade é usualmente empregada para identificar a importância de cada parâmetro de entrada, definindo como a incerteza na saída do modelo pode ser distribuída pelas diferentes fontes de incertezas na entrada do modelo (SALTELLI et al., 2004).

Os métodos de análise de sensibilidade empregados na área de desempenho de edificações podem ser divididos em abordagem local ou global. A análise de sensibilidade local está focada nos efeitos da incerteza dos fatores de entrada ao redor de um ponto específico ou caso base. As medidas de sensibilidade são usualmente calculadas fazendo com que os valores de uma variável de entrada sejam alterados enquanto os valores das demais variáveis são mantidos fixos. A análise global está mais interessada nas influências das incertezas dos fatores de entrada sobre todo o campo de saída. A abordagem global é mais precisa, mas apresenta maior demanda computacional. Os métodos de análise de sensibilidade global podem ser divididos em quatro tipos: métodos de regressão, métodos baseados em *screening* (método Morris), métodos baseados em variância (métodos FAST e Sobol) e métodos baseados em metamodelo (MARS, ACOSSO, SVM, entre outros).

A análise de sensibilidade, empregada na fase inicial de construção de um metamodelo híbrido, visa identificar quais variáveis de entrada que poderiam ser mantidas com valores fixos no procedimento de criação da base de dados, sem causar impacto significativo nos resultados, reduzindo assim a quantidade de casos simulados e o tempo

computacional. Os métodos de análise de sensibilidade mais adequados para este propósito são os métodos baseados na variância (TIAN, 2013).

Nos métodos de análise de sensibilidade baseados na variância, dois índices de sensibilidade são obtidos: um que avalia os efeitos de primeira ordem e outro que avalia os efeitos totais. Os efeitos de primeira ordem consideram os principais efeitos nas variações da saída devido ao correspondente fator de entrada. Os efeitos totais contabilizam as contribuições totais para a variância da saída devido ao correspondente fator de entrada, incluindo tanto os efeitos de primeira ordem quanto os efeitos de ordem superior que estão relacionados às iterações entre os fatores de entrada. Quando o objetivo da pesquisa é fixar fatores (variáveis) de entrada que não são importantes no modelo, os efeitos totais da análise de sensibilidade devem ser utilizados. E, quando o objetivo é priorizar as medidas de conservação de energia, os efeitos de primeira ordem são a melhor escolha (TIAN, 2013).

Os métodos baseados na variância são considerados como métodos livres, pois são adequados para análise de modelos complexos não lineares e também para modelos não aditivos. A desvantagem destes métodos é a sua alta demanda computacional. Os dois métodos mais utilizados são o FAST (*Fourier Amplitude Sensitivity Test*) e o Sobol. O método FAST considera somente os efeitos não-lineares, sem considerar os efeitos de iterações entre variáveis. O método Sobol pode decompor toda a variância da saída, sem desprezar nenhuma variância na análise. Desta forma, o método Sobol é mais preciso, mas demanda mais tempo de processamento computacional.

Há programas computacionais estatísticos para a realização de análise de sensibilidade. Tian (2013) fez uma revisão sobre o emprego de métodos de análise de sensibilidade em análises energéticas em edificações, e recomendou dois programas: o SIMLAB (SIMLAB, 2011) e o R (R, 2014). O SIMLAB é um programa gratuito para análise de incertezas e sensibilidade, e permite que o usuário faça a análise de sensibilidade com o emprego dos seguintes métodos: de regressão (índices SRC, SRRC, PCC, PRCC, SPEAR, PEAR), Morris, FAST e Sobol.

Muitas pesquisas tem empregado o SIMLAB para avaliar a importância das variáveis em análises de desempenho de edificações, tais como os trabalhos de Hopfe e Hensen (2011), Tian e de Wilde (2011), Mechri et al. (2010), de Wilde e Tian (2009), Struck et al. (2009), Corrado e Mechri (2009), e Moon (2010).

Sendo que o objetivo da análise de sensibilidade no desenvolvimento do metamodelo foi identificar quais as variáveis de

entrada poderiam ter seus valores fixos para reduzir a quantidade de casos simulados, e identificando-se que para este objetivo os métodos baseados em variância são os mais adequados, optou-se pelo uso do método Sobol, por ser este o método baseado em variância mais preciso. O Anexo C apresenta a descrição completa do método Sobol. O programa SIMLAB foi escolhido para a realização desta análise de sensibilidade.

2.1.4.2. Amostragem

Na estatística, amostragem é o processo que procura selecionar um subconjunto de uma população estatística, que será estudado e analisado de modo que seja possível, em seguida, se realizar a inferência estatística, ou seja, generalizar os resultados obtidos com a amostra para toda a população.

O uso de técnicas de amostragem na simulação de edificações busca reduzir o número de simulações computacionais necessárias, reduzindo assim o tempo computacional. As principais técnicas de amostragem empregadas nesta área são: amostragem aleatória simples, amostragem estratificada, e amostragem por Hipercubo Latino.

O método de amostragem aleatória simples é um procedimento de amostragem probabilística que dá a cada elemento da população, e a cada possível amostra de um tamanho determinado, a mesma probabilidade de ser selecionado.

O método de amostragem estratificada representa uma melhoria em relação à amostragem aleatória, pois força a amostra a obedecer toda a distribuição que está sendo analisada. Para alcançar isto, a distribuição de probabilidade da variável de interesse é tipicamente dividida em vários estratos de igual probabilidade, e um valor é então escolhido aleatoriamente dentro de cada estrato.

A amostragem pelo método Hipercubo Latino é uma evolução da amostragem estratificada, e seleciona valores aleatoriamente dentro de uma distribuição de faixas previamente distribuídas, sendo um valor pertencente a cada uma das faixas. No contexto da amostragem estatística, uma grade quadrada contendo as posições da amostra é um quadrado latino se, e somente se, há somente uma amostra em cada linha e em cada coluna. Um hipercubo latino é uma generalização deste conceito para um número arbitrário de dimensões.

Macdonald (2009) analisou estas três técnicas de amostragem na análise de incertezas pelo método de Monte-Carlo, e concluiu que, para o mesmo número de simulações, o método Hipercubo Latino é o método que produz resultados mais robustos.

Os resultados obtidos por Stein (1987) com o método de Hipercubo Latino apresentaram menor variância, do que os obtidos com o método de amostragem aleatória simples. E, Faria et al. (1999), ao aplicar diferentes métodos de amostragem a um problema de análise de risco, também verificaram que o método Hipercubo Latino proporciona uma redução na variância das estimativas, quando comparado com o método de amostragem aleatória simples.

O método Hipercubo Latino garante que cada parte da distribuição de probabilidades estará presente na amostra, levando assim a uma rápida convergência da amostra em relação à distribuição representada (FARIA et al., 1999).

Segundo Faria et al. (1999), a geração de valores amostrais pelo método Hipercubo Latino é realizada seguindo os seguintes passos:

- a) Definição do tamanho da amostra a ser gerada (n);
- b) Estratificação da distribuição acumulada em n estratos equiprováveis;
- c) Seleção, utilizando amostragem aleatória sem reposição, de um dos estratos definidos no item b;
- d) Geração aleatória de um valor amostral para o estrato selecionado;
- e) Repetição dos itens c e d até se completar o número de valores a serem gerados, ou seja, n observações.

Diante do que foi exposto acima, optou-se pelo uso da amostragem pelo método Hipercubo Latino, na presente pesquisa, para reduzir o número de simulações a serem realizadas com o objetivo de obter uma base de dados.

2.1.4.3. Treinamento do modelo

Inferência estatística é um ramo da estatística cujo objetivo é fazer afirmações a partir de um conjunto de valores representativos (amostra) sobre um universo (população). Algoritmos de aprendizado de máquina (*machine learning*) constroem um modelo matemático a partir de uma amostra de dados, conhecido como "dados de treinamento", para fazer previsões ou decisões. As principais técnicas de inferência estatística ou aprendizado de máquina, utilizadas na área de desempenho energético de edificações, conforme já descritas no item 2.1.2, são: regressão linear múltipla, máquina de vetores suporte e redes neurais artificiais.

Versage (2015) comparou metamodelos para avaliação do desempenho energético de edificações comerciais, obtidos a partir do emprego de diferentes técnicas de inferência estatística ou de aprendizado de máquina: regressão linear múltipla (MLR), regressão

adaptativa multivariada por splines, processo gaussiano (PG), máquina de vetores suporte (SVM), *Random Forest* (RF) e redes neurais artificiais (RNA). As técnicas SVM e RF foram as que exigiram maior tempo para o seu treinamento, 113,6 e 96,1 horas, respectivamente. Enquanto que as RNAs levaram 20,5 horas, e as demais menos de 10 minutos cada. Os metamodelos foram utilizados para prever a carga de refrigeração anual, e os resultados foram comparados com os valores obtidos pela simulação computacional. O coeficiente de determinação (R^2), a raiz do erro quadrático médio (RMSE) e a raiz do erro quadrático médio normalizada (NRMSE) foram utilizados para avaliar o desempenho dos metamodelos, conforme Equações 2, 3 e 4, respectivamente.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (3)$$

$$NRMSE = \frac{RMSE}{\bar{y}} \quad (4)$$

Onde:

y = valor da variável obtida por simulação;

\hat{y} = valor da variável predito pelo modelo;

n = número total de dados;

\bar{y} = média dos valores da variável obtidos por simulação.

Os metamodelos RNA e PG apresentaram os maiores valores de R^2 (0,994 e 0,981, respectivamente) e os menores valores de RMSE. Sendo que o metamodelo RNA apresentou o menor percentual de erro (0,7%) dentre todos os metamodelos. Considerando um índice de desempenho global, que inclui tempo de treinamento e os resultados de R^2 e RMSE, o metamodelo RNA obteve o melhor resultado, seguido do PG. Os piores desempenhos globais foram obtidos pelos metamodelos SVM e MLR.

Ahmad et al. (2017) compararam o desempenho do uso de redes neurais artificiais, e de *Random Forest*, na predição de consumo de energia elétrica do sistema de climatização de um hotel em Madri. Os resultados mostraram que as RNAs tiveram desempenho melhor do que o algoritmo de treinamento baseado em árvores de decisão (*Random Forest*). Ambas as técnicas mostraram bom desempenho nos dados de

treinamento e validação. No entanto, a RNA mostrou uma maior precisão nos dados de testes (*testing dataset*).

Daut et al. (2017) revisaram as pesquisas de métodos de predição de energia elétrica de edificações que empregam tanto técnicas convencionais de inferência estatística (séries temporais estocásticas e regressão linear), como técnicas de inteligência artificial (RNA e SVM). Esta revisão mostrou que as técnicas de inteligência artificial apresentam desempenho superior às técnicas convencionais na área de predição de energia em edificações. Sendo que a técnica SVM foi desenvolvida como uma forma alternativa para superar problemas de sobreajuste (*over-fitting*) que ocorre em casos com o uso da técnica de RNA.

Pino-Mejías et al. (2017) desenvolveram modelos de predição de carga térmica de aquecimento e refrigeração, consumo de energia e emissão de CO₂, para edifícios de escritórios no Chile, utilizando técnicas de regressão linear e RNAs. A pesquisa tinha como pretensão esclarecer como a carga térmica, consumo e emissões de CO₂ de edifícios de escritórios podem ser previstos no caso da aplicação da norma ISO 13790:2008. Os modelos com RNA apresentaram maior precisão nos resultados, do que os modelos obtidos com o uso de regressão linear.

O uso de técnicas de inteligência artificial, em modelos de predição, consiste em quatro etapas: obtenção dos dados, pré-processamento dos dados, treinamento do metamodelo e teste do modelo.

Depois de obter os dados e tratá-los (pré-processamento), ocorre o treinamento do metamodelo. Uma abordagem padrão é realizar uma amostragem aleatória nos dados para construir o metamodelo, e usar os demais dados para avaliar o seu desempenho. Os dados utilizados para construir o metamodelo são chamados de conjunto de treinamento, e os dados utilizados para avaliar o metamodelo são chamados de conjunto de validação.

Para a definição do tamanho da amostra a ser empregada no treinamento pode-se empregar o cálculo do tamanho da amostra por meio da estimativa da média populacional (ISRAEL, 1992), considerando a população finita, conforme Equação 5.

$$n = \frac{N \sigma^2 Z_{\alpha/2}^2}{(N - 1) E^2 + \sigma^2 Z_{\alpha/2}^2} \quad (5)$$

Onde:

n = tamanho da amostra;

N = tamanho da população;

$Z_{\alpha/2}$ = valor crítico que corresponde ao grau de confiança desejado;

σ = desvio-padrão da variável em estudo;

E = margem de erro ou erro máximo da estimativa. Indica a diferença máxima entre a média amostral e a verdadeira média populacional.

Os valores de confiança mais utilizados e os correspondentes valores de $Z_{\alpha/2}$ são apresentados na Tabela 1.

Tabela 1 – Valores críticos associados ao grau de confiança da amostra
(Fonte: Versage, 2015).

Grau de confiança	Valor crítico $Z_{\alpha/2}$
90,0%	1,645
95,0%	1,960
99,0%	2,575
99,5%	3,090
99,9%	3,291

Técnicas de reamostragem são usualmente empregadas para estimar o desempenho dos modelos: um subconjunto da amostra é usado para construir o modelo e os dados remanescentes são usados para estimar a sua eficácia. Este processo é repetido múltiplas vezes e os resultados são agregados e sumarizados. Na técnica de reamostragem chamada validação cruzada repetida de k-fold, a amostra é particionada aleatoriamente em k conjuntos de tamanhos praticamente iguais, e o modelo é treinado utilizando toda a amostra, exceto o primeiro conjunto (primeiro k-fold). Este conjunto retido é empregado como conjunto de validação para avaliar o desempenho do modelo obtido. O primeiro conjunto retorna à amostra e o processo se repete obtendo-se um novo modelo utilizando toda a amostra exceto o segundo conjunto (segundo k-fold) que é empregado como conjunto de validação, e assim por diante até o último conjunto k-fold. Ao final desta etapa (validação cruzada k-fold) são obtidos k modelos. Então, todo o processo é repetido múltiplas vezes, de tal forma que em cada repetição os conjuntos k-fold são distintos devido ao processo aleatório de particionamento. Por exemplo, se for utilizada a validação cruzada de 10 k-folds repetida cinco vezes teremos 50 diferentes modelos treinados, e o modelo escolhido será aquele que apresentar melhores indicadores de desempenho.

Medir o desempenho dos modelos é uma etapa importante (KUHN e JOHNSON, 2013). Os resíduos, que são a diferença entre o valor observado e o valor predito, são importantes fontes de informação. A raiz do erro quadrático médio (RMSE) é comumente utilizada para

avaliar modelos. O RMSE é interpretado como quão longe, na média, os resíduos estão de zero.

As técnicas de reamostragem podem ser caracterizadas em termos de viés e precisão. O viés determina a exatidão e pode ser definido como a diferença entre os valores estimados e os reais. A precisão mede quão variável é o resultado. Sendo cinco ou 10 os valores usuais para k (KUHNS e JOHNSON, 2013), o maior valor (10) resulta em uma maior exatidão (quanto menor a diferença entre a quantidade de dados utilizada para treinamento e a quantidade total de dados da amostra, menor será o viés). A precisão pode ser medida através da variância, quanto menor a variância maior a precisão. Pesquisas (MOLINARO et al., 2005 e KIM, 2009) indicam que a repetição na técnica de validação cruzada de k -fold pode ser empregada para aumentar a precisão das estimativas, ou seja, quanto maior for o número de repetições menor será a variância. KUHNS e JOHNSON (2014) demonstraram que a queda da variância, com o aumento do número de repetições, tem um comportamento exponencial.

Na presente pesquisa, a técnica utilizada para treinamento do modelo foi a de redes neurais artificiais utilizando validação cruzada repetida de k -fold, com valor de k igual a 10 (que resulta em maior exatidão, quando comparada com k igual a cinco) e repetição igual a seis. Como a queda da variância tem comportamento exponencial com o aumento do número de repetições, entendeu-se que o ganho obtido com o uso de mais de seis repetições não justificaria o aumento no tempo de treinamento.

2.2. CONSUMO DE ENERGIA DE SISTEMAS DE CLIMATIZAÇÃO

A climatização engloba o condicionamento do ar, o seu transporte, e a sua introdução no ambiente climatizado. O condicionamento do ar pode incluir aquecimento, resfriamento, umidificação, desumidificação e filtragem. Os sistemas de climatização, por meio de seus equipamentos e componentes, tem a função de controlar e manter temperatura, umidade, movimentação do ar, qualidade do ar e diferencial de pressão no ambiente, dentro de limites predeterminados para a obtenção do conforto e saúde dos ocupantes do espaço condicionado. Na literatura internacional é usual se referir aos sistemas de climatização pela sigla HVAC (*Heating, Ventilating, and Air Conditioning*).

Os sistemas de climatização podem ser classificados de acordo com sua aplicação em sistemas de climatização para conforto e sistemas de

climatização para processos. O primeiro proporciona aos ocupantes um ambiente interno confortável e saudável para realizarem suas atividades, e o segundo fornece controle ambiental interno necessário para a fabricação, produção ou armazenamento de produtos.

Os sistemas de climatização também podem ser classificados de acordo com suas características construtivas e operacionais em: sistemas individuais, sistemas de resfriamento evaporativo, sistemas com rotores dessecantes, sistemas com termoacumulação, sistemas de salas limpas, sistemas de condicionamento de ambiente, e sistemas unitários (WANG, 2001).

Os sistemas de água gelada, foco da presente pesquisa, são também chamados de sistemas centrais. Nestes sistemas o ar é resfriado ou aquecido por trocadores de calor (serpentinhas) nos quais circulam internamente água fria ou quente, distribuída por uma planta central de refrigeração ou aquecimento. Este sistema é utilizado em grandes edificações que possuem muitas zonas térmicas. A capacidade térmica da água é superior à do ar (3.466 vezes maior, à 20°C). Assim, é mais eficiente utilizar água para transportar energia térmica da central até os climatizadores. No entanto, um sistema de água gelada torna projetos de pequeno e médio porte mais complicados e caros, quando comparados a outros tipos de sistemas.

O sistema de água gelada é composto por um sistema de tratamento de ar, um sistema de distribuição de água, uma central de água gelada/água quente, e um sistema de controle. A Figura 2 apresenta um esquema típico de um sistema de água gelada.

O sistema de tratamento de ar é composto pelos climatizadores, dutos de ar, difusores, grelhas, caixas ventiladoras e exaustores. O climatizador é usualmente composto por ventilador, filtros, serpentina de resfriamento, serpentina de aquecimento, caixa de mistura e acessórios. O sistema de tratamento de ar pode apresentar vazão de ar constante (VAC) ou vazão de ar variável (VAV).

O sistema de distribuição de água engloba as tubulações e bombas hidráulicas de água gelada, água quente e de água de condensação. A função deste sistema é transportar água da central para os climatizadores e para a torre de resfriamento. As bombas podem apresentar vazão constante ou variável.

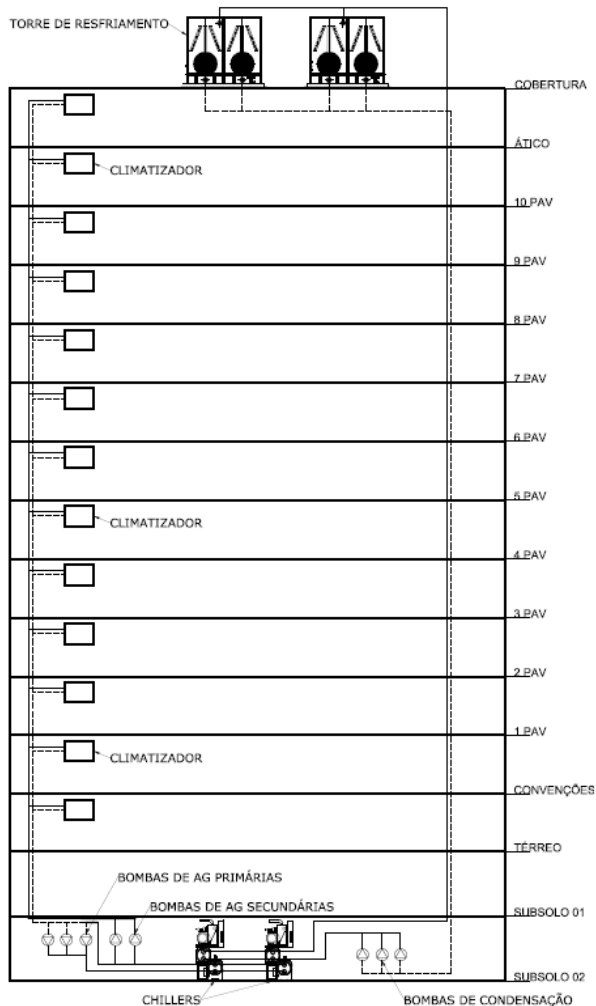


Figura 2 – Típico sistema de climatização do tipo água gelada (Fonte: Autor).

A central de água é formada por um ou mais resfriadores de líquidos (*chillers*) que tem a função de produzir a água gelada, e por uma ou mais caldeiras (*boilers*) que produzem a água quente. O resfriamento da água é proporcionado pelo sistema de refrigeração presente no *chiller*. O ciclo de refrigeração mais empregado em *chillers* é o de compressão mecânica de vapor. A água gelada circula pelo evaporador de tal forma

que o ciclo de refrigeração retira calor da água fazendo baixar a sua temperatura. Quando o condensador do chiller rejeita calor diretamente para o ar, diz-se que o *chiller* é do tipo condensação a ar, e quanto rejeita calor para outro circuito de água, diz-se que o *chiller* é do tipo condensação a água. Este circuito de água, responsável por receber o calor rejeitado no ciclo de refrigeração, é chamado circuito de água de condensação. A água de condensação aumenta sua temperatura ao passar pelo *chiller*, e é feita circular através de uma torre de resfriamento para reduzir sua temperatura.

O ciclo de refrigeração apresenta maior eficiência energética quanto maior for a sua temperatura de evaporação, e menor for a sua temperatura de condensação. Desta forma, os *chillers* com condensação a água apresentam maior eficiência, quando comparados com o *chillers* com condensação a ar, porque operam com menores temperaturas de condensação.

Os sistemas de controle nos sistemas centrais consistem de sensores eletrônicos, microprocessadores e módulos de controle, os quais podem analisar e realizar cálculos a partir de entradas de sinais analógicas ou digitais. As saídas dos módulos de controle frequentemente acionam atuadores elétricos de registros de ar (*dampers*) e válvulas, ou relés.

A eficiência energética em edificações, com foco no consumo de energia em climatização, pode ser obtida através de três etapas: projeto eficiente da envoltória, emprego de equipamentos de alta eficiência e utilização de sistema otimizado de controle (CHO et al., 2014). O presente trabalho não abordará os aspectos de projeto de envoltórias eficientes, tampouco a otimização de sistema de controle. O objetivo é obter um método simplificado que permita estimar o consumo de energia de sistemas de climatização quando em operação em uma edificação.

A determinação do consumo de energia do sistema de climatização de uma edificação não é uma tarefa fácil, e segundo Pérez-Lombard et al. (2011a) falta uma estrutura coerente e uniforme para guiar eficientemente as políticas e as pesquisas na área de eficiência energética de sistemas de climatização, principalmente devido à complexidade e variedade dos sistemas, e ao insuficiente rigor em suas análises de energia. Os autores propuseram uma análise dos sistemas de climatização através do mapeamento do fluxo de energia, desde as fontes de energia até a entrega dos serviços finais (conforto térmico), examinando os componentes intermediários que formam os elos da cadeia global de energia. Nos diagramas de fluxo de energia apresentados para um típico sistema de climatização de edifícios de

escritórios na Espanha (água gelada com vazão de ar constante) pode-se observar que do consumo total do sistema, 76,1% é devido ao *chiller*, 3,2% devido às bombas e 20,7% devido aos ventiladores, quando o *chiller* é condensação a ar; e 65,0% é devido ao *chiller*, 3,8% devido às bombas de água gelada, 24,7% devido aos ventiladores, 4,0% devido à torre de resfriamento, e 2,5% devido às bombas de água de condensação, quando o *chiller* é condensação a água. Yu e Clan (2005) em seus trabalhos já afirmavam que o consumo do *chiller* representa cerca de 60% do consumo total deste tipo de sistema de climatização.

Além da importância da avaliação do desempenho global incluindo todos os componentes, outro fator que merece bastante atenção na determinação do consumo de sistema de climatização é o seu comportamento em condições reais de uso. Os sistemas de climatização são projetados para promover o conforto mesmo em condições críticas, de acordo com o clima local e as características de uso da edificação, mas eles normalmente operam em condições mais leves. Sendo assim, os seus equipamentos são dimensionados pelas cargas térmicas de pico da edificação, mas usualmente operam em condições de carga parcial. As condições nominais de classificação de eficiência energética dos equipamentos não representam as condições usuais de uso destes equipamentos (CECHINATO, 2010).

A indústria de equipamentos de climatização tem se esforçado para encontrar maneiras fáceis e rápidas de avaliar o desempenho dos equipamentos em carga parcial, como por exemplo, o desempenho dos *chillers*. Esta procura por resultados rápidos levou muitos engenheiros a usar métodos de avaliação a partir de um único valor, como o IPLV (*Integrated Part Load Value*) (AHRI, 2011). A fórmula do IPLV, como definido pela *AHRI Standard 550/590*, é usada para classificar um *chiller* em carga parcial, e é baseada no comportamento médio de edifícios e condições climáticas de 29 cidades dos Estados Unidos. Para uma edificação específica localizada em um determinado clima, o uso do IPLV pode não levar à seleção de uma solução otimizada, sendo que uma simulação anual é a forma mais precisa para comparar o desempenho de *chillers* sob as condições reais de carga (YU e CHAN, 2006). Os motivos pelos quais o IPLV não representa com precisão as características de funcionamento em carga parcial de uma central de água gelada, principalmente se ela for composta por dois ou mais *chillers*, são apresentados nos artigos de Geister e Thompson (2009) e de Yu e Chan (2006). Um primeiro motivo é que o IPLV assume que somente 1% do tempo de operação do *chiller* ocorre com altas cargas, e que 57% do tempo ocorre em cargas de 50% ou menos. Para centrais

com múltiplos *chillers* há um sequenciamento de operação (um segundo *chiller* somente entra em operação depois que o primeiro *chiller* chega próximo a sua capacidade máxima, passando os dois a operar com cargas parciais iguais e próximas a 50% no primeiro momento) onde o percentual de operação dos *chillers* em baixa carga (inferior a 50%) é bastante inferior aos 57% considerados no IPLV, bem como ocorre a operação dos *chillers* em carga plena em tempo superior a 1%. Um estudo de caso realizado por Geister e Thompson (2009) ilustrou que um sistema simulado para 41 cidades distintas apresentou tempos de operação média de 45%, 28%, 9% e 18% para 100%, 75%, 50% e 25% de carga dos *chillers*, distintos dos valores considerados no IPLV (1%, 42%, 45% e 12%). Outro motivo é que o IPLV considera que em 57% do tempo o *chiller* opera com temperatura de condensação igual a 18,3°C ou menos, e somente 1% com temperatura de condensação superior a 23,9°C. Esta temperatura é função do clima, estando limitada pela temperatura de bulbo úmido externa (TBU), e em muitos lugares do mundo os valores considerados no IPLV nunca são atingidos durante a operação do sistema. A norma brasileira NBR 16401 (ABNT NBR 16.401, 2008) apresenta valores de TBU para projeto de 36 cidades, todos superiores a 21,1°C, com um valor médio de 25,6°C. O IPLV também não considerou o uso de inversores de frequência quando da sua elaboração, sendo assim o seu uso para analisar *chillers* com inversores de frequência, principalmente com compressores centrífugos, pode levar a resultados equivocados.

Nos últimos anos a importância das condições de carga parcial na estimativa do desempenho de equipamentos de climatização em condições reais de operação tem sido completamente reconhecida, sendo que alguns métodos já existem em alguns regulamentos de eficiência energética, mas não apresentam uma extensa validação em sistemas de climatização reais (SCHIBUOLA et al., 2014).

Os sistemas de climatização são complexos, apresentam comportamento não linear, e contêm uma grande quantidade de variáveis. O processo de modelagem e otimização destes sistemas é um desafio. O desempenho de um sistema de climatização depende de muitos fatores, incluindo as características da edificação, o clima, as condições de uso, o tipo de sistema, a eficiência dos componentes do sistema, e a estratégia de controle.

A forma mais precisa para realizar a análise de desempenho é o uso da simulação do conjunto sistema/edificação, de forma detalhada e integrada. O consumo anual de energia do sistema de climatização é estimado através do emprego de ferramentas computacionais que

realizam a simulação horária (ou sub-horária), com base no conjunto de equações que modelam o comportamento térmico da edificação e a operação do sistema.

Uma grande quantidade de programas computacionais de simulação tem sido desenvolvida nas últimas décadas, sendo que os vinte principais são BLAST, BSim, DeST, DOE-2.1E, ECOTECT, Ener-Win, Energy Express, Energy-10, EnergyPlus, eQUEST, ESP-r, HAP, HEED, IDA ICE, IES<VE>, PowerDomus, SUNREL, Tas, TRACE e TRNSYS. Buscando contrastar as características e funcionalidades destes vinte programas de simulação de edificações, Crawley et al. (2008) realizaram uma pesquisa comparando estes programas com base nas informações fornecidas pelos seus desenvolvedores. Nesta comparação, os programas que apresentam mais funcionalidades relacionadas à modelagem de sistemas de climatização são: EnergyPlus, eQUEST, IDA ICE, TRACE e TRNSYS. Em outro artigo, Nguyen et al. (2014) constataram que os dois programas de simulação mais citados na base de dados Scopus entre 2000-2013, utilizados em métodos de otimização aplicados à análise de eficiência de edificações, foram o EnergyPlus (37,2% dos artigos) e o TRNSYS (35,2%).

Os programas de simulação de edificações, com relação a sua estrutura geral, podem ser classificados como modelos baseados em sistema, em componente ou em equação. O BLAST, IBLAST e DOE-2 podem ser descritos como simuladores baseados em sistema, pois modelam os sistemas mecânicos como blocos monolíticos de código ou como uma coleção de subrotinas fortemente acopladas e especializadas. Esta abordagem é vantajosa porque permite que o método de solução possa ser adaptado para cada tipo de componente e sistema, e resulta em modelos que tendem a ser bastante robustos. Além disso, a entrada de dados necessária para descrever um sistema ou componente é simplificada, pois grande parte desta informação já se encontra na estrutura do código. Por outro lado, há a desvantagem de que novos modelos são difíceis de serem desenvolvidos e implementados, bem como os modelos existentes são difíceis de serem alterados.

Programas como o HVACSIM+, TRNSYS, ESP-r, SPARK e IDA, modelam os sistemas de climatização e equipamentos mecânicos com base no componente ou em equações. Sistemas completos são definidos através da relação entre componentes ou equações. Esta abordagem torna possível desenvolver uma ampla gama de novos sistemas pela conexão de diferentes combinações de componentes. Um sofisticado programa de solução numérica é necessário para a obtenção da solução simultânea de todos os elementos da simulação. Outras desvantagens

são que complexas conexões entre os componentes devem ser desenvolvidas e especificadas como entrada da simulação; e que a abordagem dificulta o processo de encapsulamento de dados afetando a extensão e a manutenção do código.

O processo de simulação dos sistemas de climatização no Energyplus emprega uma abordagem híbrida de ambiente baseado em componente e em sistema. A presença de *loops*, que modelam as tubulações e os dutos, gera uma estrutura característica de modelos baseados em sistema, enquanto que a presença de componentes, cujas conexões no *loop* e características são descritas nos dados de entrada, gera uma característica de flexibilidade dos modelos baseado em componente. Esta abordagem híbrida permite o acoplamento de diferentes componentes para formar várias configurações de sistemas, e a estrutura de dados bem definida facilita a extensão e a modificação de módulos de simulação. Outros detalhes a respeito desta abordagem podem ser encontrados em Fisher et al. (1999).

O emprego da simulação detalhada exige muito esforço e consome muito tempo, resultando em custos mais elevados que precisam ser justificáveis. Resultados satisfatórios podem ser obtidos com o emprego de simplificações (KLIMCZAK et al., 2018). Métodos simplificados são úteis e apropriados quando o propósito da análise é avaliar tendências e/ou comparar sistemas alternativos (WANG e ZHAI, 2016).

Ao revisar os processos de modelagem e simulação de sistemas de climatização, Trcka e Hensen (2010) afirmaram que a maioria das análises de projeto não necessita de modelagem e simulação detalhadas, e que o consumo de energia pode ser estimado por meio de metodologia simplificada. A representação conceitual do sistema é mais vantajosa (menor experiência do usuário é necessária, menor número de dados de entrada, menor processamento computacional, análise facilitada dos resultados, entre outras vantagens) quando somente previsões de carga são analisadas, e/ou quando opções de conservação de energia são investigadas. Contudo, modelos detalhados são necessários quando o objetivo é comparar tipos alternativos de sistemas de climatização ou avaliar diferentes estratégias de controle.

Augenbroe et al. (2013) também investigaram se a simulação integrada sistema/edificação é sempre necessária e relevante, dado ao fato de que esta abordagem é computacionalmente intensa e requer um esforço substancial, por parte de profissionais altamente qualificados, para modelar todos os detalhes complexos dos sistemas de climatização. Os resultados de cinco estudos de caso, utilizando simulação integrada e não integrada do sistema de climatização com a edificação, mostraram

uma boa concordância, visto que a diferença máxima observada no consumo mensal de energia foi de 20%. A simulação não integrada é uma forma simplificada de simulação, onde o desempenho do sistema de climatização é obtido de forma desacoplada da edificação, e assim as iterações dinâmicas entre os lados da demanda e do fornecimento são ignoradas.

As pesquisas mencionadas nos dois parágrafos anteriores demonstram que métodos simplificados podem ser empregados para estimar o consumo de energia de sistemas de climatização, com vantagens sobre o uso de métodos complexos de simulação detalhada, corroborando assim a proposta do presente trabalho.

2.3. CARACTERIZAÇÃO DO CLIMA EM MODELOS SIMPLIFICADOS

O clima, caracterizado principalmente pela temperatura, umidade, velocidade do vento e radiação, é um fator determinante na carga térmica de resfriamento ou aquecimento em edificações, assim como na eficiência dos equipamentos do sistema de climatização. Por exemplo, *chillers* com condensação a ar operam com maior eficiência energética quando a temperatura externa é menor. Arquivos climáticos são utilizados na simulação computacional de edificações, enquanto correlações climáticas são utilizadas em métodos simplificados de predição de energia em edificações. As correlações climáticas, também chamadas de indicadores climáticos, usualmente encontrados na literatura, são o *heating degree days* (HDD) e o *cooling degree days* (CDD).

Segundo McQuiston et al. (2005), o método graus-dia foi o primeiro método desenvolvido para estimar a energia de aquecimento em residências unifamiliares, e o procedimento foi baseado na hipótese de que no longo prazo, os ganhos solares e internos da estrutura da residência se equilibrariam com as perdas de calor pela envoltória quando a temperatura externa fosse igual a 18°C (temperatura base). Ou seja, a edificação somente necessitaria de aquecimento quando a temperatura externa fosse menor do que a temperatura base, neste modelo, 18°C. O consumo de combustível utilizado no sistema de aquecimento é calculado neste método pela Equação 6 e Equação 7.

$$DD = \frac{(t - t_a) \cdot N}{24} \quad (6)$$

$$F = \frac{24 \cdot DD \cdot \dot{q} \cdot C_D}{\eta \cdot (t_i - t_o) \cdot H} \quad (7)$$

Onde:

DD = graus-dia para o período desejado;

t = temperatura base (18°C);

t_a = temperatura média exterior, em °C;

N = número de horas em que a temperatura média t_a é computada no período;

F = quantidade de combustível necessário para o período desejado;

q̇ = perda de calor total com base nas temperaturas de projeto, interna (t_i) e externa (t_o);

C_D = fator de correção;

η = fator de eficiência;

H = poder calorífico do combustível;

Com base neste método, que considera que o consumo de energia de aquecimento é diretamente proporcional ao valor do graus-dia, o indicador climático HDD (*heating degree days*) é internacionalmente empregado como fator de correção climática em modelos de predição de consumo de energia de aquecimento de edificações (Energystar, 2017). O HDD é definido como a soma das diferenças positivas entre as temperaturas base e externa em um dado período, conforme a seguinte Equação 8.

$$HDD = \sum_{n=1}^N (t_b - \bar{t}_o)^+ \quad (8)$$

Onde:

HDD = *heating degree days*,

N = número de dias do período analisado,

̄t_o = temperatura média externa diária, em °C,

t_b = temperatura base, em °C.

O sinal positivo (+) sobrescrito nas equações indica que somente são considerados na somatória os resultados positivos da subtração descrita entre parênteses.

De forma análoga, existe a definição do indicador *cooling degree days* (CDD), que permite avaliar a influência do clima no consumo de energia de resfriamento de uma edificação, e é calculado pela Equação 9.

$$CDD = \sum_{n=1}^N (\bar{t}_o - t_b)^+ \quad (9)$$

Onde:

$CDD = \text{cooling degree days}$,
 $N =$ número de dias do período analisado,
 $\bar{t}_o =$ temperatura média externa diária, em $^{\circ}\text{C}$,
 $t_b =$ temperatura base, em $^{\circ}\text{C}$.

A temperatura base é definida individualmente para cada edificação, mas é comum o emprego de certos valores para os quais são publicados o HDD e o CDD referente ao clima de certas cidades. A ASHRAE (*American Society of Heating, Refrigerating and Air-Conditioning Engineers*), por exemplo, publica os valores de CDD para as temperaturas de 10,0; 18,3; 23,3 e 26,7 $^{\circ}\text{C}$, para diversas cidades americanas e de outros países (ASHRAE, 2013).

Utilizando o mesmo conceito empregado para o cálculo do graus-dia, o indicador climático também pode ser calculado considerando a temperatura média de cada hora, e não a temperatura média diária. Para o resfriamento, tem-se o chamado *cooling degree hours* (CDH), conforme a Equação 10.

$$CDH = \sum_{n=1}^N (t_o - t_b)^+ \quad (10)$$

Onde:

$CDH = \text{cooling degree hours}$;
 $N =$ número total de horas consideradas;
 $t_o =$ temperatura externa à edificação na hora n , em $^{\circ}\text{C}$;
 $t_b =$ temperatura base, em $^{\circ}\text{C}$.

Segundo Papakostas and Kyriakis (2005) o CDH, quando comparado ao *cooling degree days* (CDD), representa melhor o período em que o sistema de climatização está em operação, e resulta em estimativas de consumo mais precisas, visto que, durante a estação de resfriamento, o início da operação do sistema pode ser adiado com a abertura de janelas, especialmente durante a noite, quando a temperatura externa é usualmente abaixo da temperatura base.

Regiões com clima quente e úmido apresentam uma grande quantidade de carga latente na carga térmica de resfriamento das edificações. Os indicadores CDD e CDH são calculados com o uso da temperatura de bulbo seco, e sendo assim, negligenciam a influência da parcela de carga latente na carga térmica de resfriamento. Portanto, é necessário buscar por novos indicadores que também considerem a presença do calor latente na carga térmica de resfriamento das edificações. Huang et al. (1986), Sailor e Muñoz (1997), Sailor (2001) e Krese et al. (2011) utilizaram o ELD (*Enthalpy Latent Days*) para

incorporar tal influência em seus cálculos, enquanto os trabalhos de Shin e Do (2016), Bloomfield et al. (2010) e Borgstein e Lamberts (2014) empregaram um único indicador climático para considerar ambas as parcelas (sensível e latente) através do emprego da entalpia ou da temperatura de bulbo úmido.

O trabalho de Shin e Do (2016) utilizou o conceito de CDD para desenvolver modelos preditivos de consumo de energia para duas edificações no Texas. Dois modelos foram desenvolvidos, um utilizou CDD calculado com a temperatura de bulbo seco (CDD_T) conforme Equação 9, e outro calculado com a entalpia (CDD_H) conforme Equação 11. Os resultados mostraram que a relação entre o CDD_H e o consumo de energia para resfriamento (valores medidos) foi significativamente melhorada (cerca de 10% maior), quando comparada com a relação que utilizou o CDD_T ($R^2=0,8142$ com o CDD_T , e $R^2=0,9174$ com o CDD_H , para os dias de semana). O erro percentual médio na predição do consumo de energia de resfriamento utilizando o CDD_T foi de 4%, enquanto que com o uso do CDD_H foi de 2%, o que permitiu concluir que o CDD_H providencia resultados mais precisos na predição em climas onde a necessidade por resfriamento é dominante.

$$CDD_H = \sum_{n=1}^N (\bar{h}_o - h_b)^+ \quad (11)$$

Onde:

CDD_H = *cooling degree days* empregando somente a entalpia;

N = número de dias do período analisado;

\bar{h}_o = entalpia média externa diária, em kJ/kg;

h_b = entalpia base, em kJ/kg.

Considerando que este indicador climático também pode ser calculado com a entalpia média de cada hora, e não a entalpia média diária, obtém-se o indicador CDH_H , conforme a Equação 12.

$$CDH_H = \sum_{n=1}^N (h_o - h_b)^+ \quad (12)$$

Onde:

CDH_H = *cooling degree hours* empregando somente a entalpia;

N = número de horas do período analisado;

h_o = entalpia externa à edificação na hora n , em kJ/kg;

h_b = entalpia base, em kJ/kg.

No presente trabalho, o clima foi representado através de um indicador climático, que se caracterizou como uma das variáveis de

entrada da rede neural artificial. No clima brasileiro há predomínio de cidades onde a necessidade de resfriamento é dominante, bem como muitas apresentam alta umidade. Sendo assim, um estudo foi realizado para identificar qual o indicador climático a ser utilizado, entre o CDH, o CDH_H , e outro indicador desenvolvido nesta pesquisa.

2.4. CONSIDERAÇÕES FINAIS

A revisão bibliográfica permitiu identificar os métodos utilizados para estimar o consumo de energia em edificações (métodos de engenharia, métodos guiados por dados e métodos híbridos), com suas vantagens e limitações, bem como verificar que métodos simplificados também podem ser empregados. Houve também a identificação de que muitos dos métodos simplificados estimam somente a carga térmica, e não a energia que o sistema de climatização consome para atender esta carga térmica. Sendo assim, o presente trabalho tem por finalidade contribuir com esta lacuna de pesquisa.

A análise de eficiência energética de sistemas de climatização em condições reais de operação, devido à complexidade destes sistemas, não é uma tarefa fácil. O método de simulação horária integrada edificação/sistema é a forma mais precisa para comparar o desempenho destes sistemas, mas de uso restrito, pois demanda muito tempo e qualificação profissional. Métodos simplificados podem ser empregados quando o objetivo é estimar o consumo de energia dos sistemas de climatização. No entanto, os métodos simplificados utilizados atualmente, baseados na aplicação de uma eficiência sobre a carga térmica da edificação, ou no emprego de um índice de eficiência de um único componente do sistema em carga parcial (IPLV, por exemplo), não são eficazes.

Identificou-se que o desenvolvimento de um metamodelo, objetivo da presente pesquisa, requer a realização de três etapas: seleção de parâmetros e valores relevantes, amostragem de um conjunto representativo, e treinamento do modelo. A primeira etapa é usualmente realizada através do uso de métodos de análise de sensibilidade, dentre os quais, os métodos baseados em variância (Sobol e FAST) são os mais adequados quando o objetivo é reduzir o número de simulações fixando os valores dos parâmetros de entrada de menor influência, sendo o método Sobol, o método mais preciso. Dentre as técnicas de amostragem empregadas na área de simulações de edificações (amostragem aleatória simples, estratificada e por Hipercubo Latino), pesquisas demonstraram que a amostragem por Hipercubo Latino produz resultados mais robustos. Com relação à última etapa,

treinamento do modelo, a revisão bibliográfica mostrou que as três principais técnicas empregadas são: regressão linear múltipla, máquina de vetores suporte (SVM) e redes neurais artificiais (RNA). Pesquisas comparativas demonstram que modelos de predição de energia em edificações apresentam melhor precisão quando técnicas de inteligência artificial são empregadas (SVM e RNA); sendo que as RNA demandam menor tempo de treinamento.

Um fator determinante no consumo de sistemas de climatização é o clima. Em métodos simplificados de predição de energia em edificações são empregadas correlações climáticas, também chamadas de indicadores climáticos, para caracterizar o clima. A revisão mostrou que para climas quentes e úmidos, como é o caso do clima brasileiro, os indicadores climáticos que são calculados somente com a temperatura de bulbo seco (CDD e CDH) negligenciam a carga latente presente na carga térmica de resfriamento de edificações. Novos indicadores, que buscam sanar tal deficiência, têm sido propostos em pesquisas recentes, e serão foco de estudo nesta pesquisa.

3. MÉTODO

Este capítulo tem por finalidade apresentar o método adotado na condução desta pesquisa. Para fins de desenvolvimento, o trabalho foi dividido em duas fases. Na primeira fase, foram realizadas simulações de edifícios de escritórios com o objetivo de obter uma base de dados, a qual foi empregada para o desenvolvimento de metamodelos de predição de consumo de energia de sistemas de climatização do tipo água gelada. A segunda fase consistiu no treinamento de metamodelos, avaliação do desempenho destes metamodelos, e escolha do metamodelo final.

As etapas que compõem as fases da pesquisa são descritas em detalhes nas seções apresentadas a seguir. A Figura 3 apresenta, de forma esquemática, estas etapas e fases. E a Tabela 2, apresenta as etapas da pesquisa com os respectivos resultados esperados.

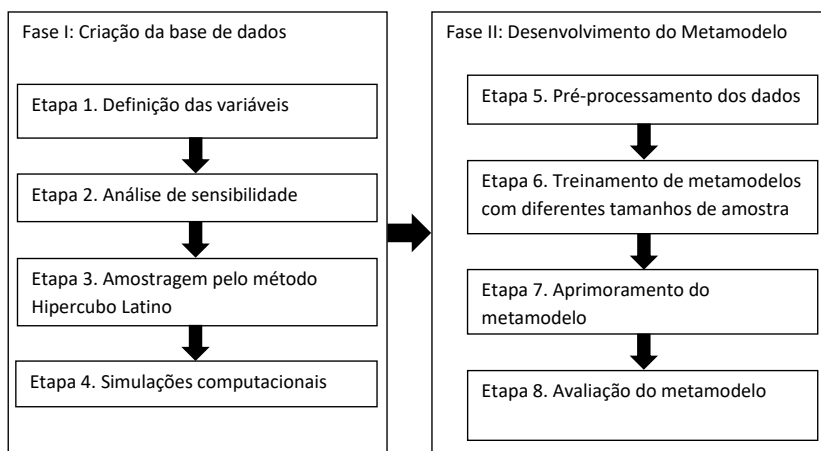


Figura 3 – Fases e etapas da pesquisa

Tabela 2 - Relação entre etapas e resultados esperados.

Etapas da pesquisa	Resultados esperados
Etapa 1	Especificação das variáveis que caracterizam a edificação, o sistema de climatização, e o clima.
Etapa 2	Definição das variáveis de menor influência nos resultados de carga térmica integrada anual de resfriamento e consumo do sistema de climatização, cujos valores puderam permanecer fixos no processo de obtenção da base de dados.
Etapa 3	Obtenção da amostra dos casos simulados para construir a base de dados.
Etapa 4	Obtenção da base de dados por meio da simulação computacionais dos casos definidos na etapa anterior.
Etapa 5	Exclusão de dados oriundos de simulações que apresentaram erros ou subdimensionamento do sistema de climatização. Obtenção de uma base de dados mais estável através de transformações (adição de parâmetros substitutos, transformação para normalização, centralização e escalonamento dos dados).
Etapa 6	Definição do tamanho de amostra empregada no treinamento dos metamodelos.
Etapa 7	Obtenção dos metamodelos de melhor relação desempenho/complexidade.
Etapa 8	Obtenção do desempenho dos modelos resultantes da etapa anterior na predição de consumo de novos casos. Escolha do metamodelo final da tese. Avaliação do desempenho do metamodelo na predição de consumo para cidades que apresentam indicador climático semelhante, mas valores distintos de radiação solar.

3.1. FASE I – CRIAÇÃO DA BASE DE DADOS

Esta fase se caracterizou pela criação de uma base de dados para representar os edifícios de escritórios com sistemas de climatização do tipo água gelada usualmente encontrados no mercado. Esta base de dados foi empregada no treinamento de metamodelos e na sua validação. A base de dados foi obtida através do emprego de simulação, com o uso do programa computacional EnergyPlus. Houve a

necessidade de simular o conjunto edificação e sistema de climatização, uma vez que os dados disponíveis de outras pesquisas, realizadas no LabEEE, dispunham somente da carga térmica integrada anual de refrigeração das edificações, ou quando dispunham do consumo de energia do sistema de climatização, este se referia à sistema split ou condicionador de janela.

A seguir serão descritas as etapas que compuseram esta fase.

3.1.1. Etapa 1 – Definição das variáveis

O objetivo desta etapa foi definir as variáveis que caracterizariam a edificação, o sistema de climatização e o clima. A seguir são apresentadas as considerações adotadas.

A geometria da edificação foi modelada considerando um pavimento retangular que se repete em todos os demais pavimentos. Cada pavimento foi modelado com quatro zonas térmicas perimetrais e uma zona térmica interna, sendo utilizada a distância entre pisos sempre igual à 3 (três) metros. As zonas perimetrais da edificação foram consideradas como as regiões que se estendem desde cada fachada até 4,5 metros em direção ao interior da edificação. O pavimento térreo foi considerado em contato com o solo, e modelado com o uso do pré-processador do EnergyPlus denominado Slab (MAZZAFERRO et al., 2013). A Figura 4 ilustra a geometria típica utilizada, bem como as zonas térmicas consideradas.




Figura 4 – Geometria típica utilizada e suas zonas térmicas.

As variáveis empregadas para caracterizar a geometria foram:

- Largura do pavimento tipo, em metros;
- Relação de aspecto entre o comprimento e a largura do pavimento tipo;
- Número de pavimentos da edificação;
- Percentual de abertura nas fachadas (*WWR – Window Wall Ratio*), idêntico nas quatro fachadas;
- Orientação solar da edificação;

As propriedades térmicas dos materiais que constituem a edificação foram caracterizadas pelas seguintes variáveis:

- Fator solar dos vidros;
- Transmitância térmica do material do vidro, em $W/m^2.K$;
- Absortância solar das paredes externas;
- Transmitância térmica das paredes externas, em $W/m^2.K$;
- Capacidade térmica das paredes externas, em $kJ/m^2.K$;
- Absortância solar da cobertura;
- Transmitância térmica da cobertura, em $W/m^2.K$;
- Capacidade térmica da cobertura, em $kJ/m^2.K$;
- Capacidade térmica das paredes internas, em $kJ/m^2.K$;

A edificação foi modelada sem considerar nenhuma proteção externas nas aberturas (brises ou marquises). Entende-se que a influência deste tipo de proteção pode ser modelada com o emprego de valores equivalente de fator solar do vidro. Desta forma a parametrização do valor do fator solar do vidro permite avaliar a influência do sombreamento nas aberturas de uma forma geral.

O sistema de iluminação, os equipamentos e as pessoas no interior da edificação geram calor nos ambientes. Nos dias quentes, a infiltração indesejada de ar externo, também gera uma parcela de calor que necessita ser retirada pelo sistema de climatização. A seguir são listadas as variáveis adotadas que estão relacionadas a estas características:

- Infiltração de ar, em trocas de ar por hora;
- Densidade de potência de iluminação, em W/m^2 ;
- Índice de ocupação, em m^2 /pessoa;
- Perfil de uso da edificação, ou horário de funcionamento, em horas de funcionamento diárias.

Na modelagem da dissipação do sistema de iluminação, o calor é dividido em quatro diferentes frações: radiante (radiação de longo comprimento de onda), visível (radiação de curto comprimento de onda), dissipada no retorno do ar, e convectiva. Foi utilizada nos

modelos uma luminária de sobrepor com lâmpadas T5, que se caracteriza por apresentar 0% de fração dissipada no retorno do ar, 27% de fração radiante, 23% de fração visível e 50% de fração convectiva (U.S. DOE, 2016).

Com relação à dissipação de calor devido aos ocupantes da edificação, foi considerado nos modelos o valor de dissipação de 120 W por pessoa, sendo que 40% deste valor é dissipado na forma de calor latente e 60% na forma de calor sensível. Da parcela sensível, 60% é dissipado por radiação e 40% por convecção (ABNT NBR 16.401, 2008).

Dunn e Knight (2005), ao realizarem um levantamento de carga de equipamentos em escritórios do Reino Unido, verificaram que existe uma forte correlação entre a densidade de potência de equipamentos (W/m^2) e o índice de ocupação ($m^2/pessoa$). Seus resultados foram apresentados em forma de tabelas e gráficos, a partir dos quais foi ajustada aqui a Equação 13 (onde $R^2=0,91$):

$$DPE = 131,43 \cdot (IOc)^{-0,923} \quad (13)$$

Onde:

DPE = densidade de potência de equipamentos (W/m^2);

IOc = índice de ocupação ($m^2/pessoa$)

O valor médio de carga de equipamentos encontrado naquela pesquisa foi de 158 W por pessoa. No entanto, devido ao contínuo crescimento na eficiência deste tipo de equipamento, este valor tem sido reduzido nos últimos anos. Korolija (2013) mencionou em seu artigo o valor de 140 W por pessoa, uma redução de 11,4% em relação aos valores de Dunn e Knight. Sendo assim, aplicando esta redução sobre a Equação 13, obteve-se aqui a Equação 14.

$$DPE = 116,45 \cdot (IOc)^{-0,923} \quad (14)$$

Esta equação foi empregada para a obtenção dos valores da densidade de potência de equipamentos a partir dos valores definidos para o índice de ocupação.

Na modelagem da dissipação térmica dos equipamentos, a energia é dividida em quatro diferentes frações: calor latente, calor radiante, fração perdida (trabalho mecânico) e calor convectivo. Como os equipamentos empregados em escritórios são basicamente computadores e impressoras, as frações de calor latente e de trabalho mecânico são nulas. Neste trabalho foi considerado que a dissipação de calor destes equipamentos ocorre 50% por radiação e 50% por convecção.

O sistema de climatização utilizado foi um sistema de água gelada modelado através do emprego de climatizadores do tipo *fancoil* e resfriador de líquido (*chiller*). As características do sistema de climatização foram representadas pelas seguintes variáveis:

- Temperatura do termostato: O valor de temperatura escolhido para que o sistema de climatização mantenha no interior da edificação irá impactar na carga térmica integrada anual de refrigeração e no consumo do sistema de climatização. Sendo assim, tal variável foi incluída na modelagem para caracterizar o sistema de climatização.
- Uso de ciclo economizador e recuperador de calor: Um recurso que pode ser empregado para reduzir o consumo do sistema de climatização é o ciclo economizador. Este recurso consiste em empregar 100% de ar externo nos climatizadores (fancoils), nos momentos em que as condições do ar externo são mais favoráveis do que as condições do ar de retorno (entalpia do ar externo menor do que a entalpia do ar de retorno). Tal condição ocorre em dias de clima ameno em edificações onde a geração de cargas internas é significativa, e principalmente em cidades onde há grandes diferenças diárias de temperatura e baixa umidade. Outro recurso que pode ser empregado para reduzir o consumo do sistema de climatização é o uso de recuperador de calor. O recuperador de calor consiste em recuperar parte da energia que seria perdida com a parcela de ar climatizado que é descartada em virtude da taxa de renovação de ar, a qual é necessária para manter a qualidade do ar interior nas edificações. O recuperador de calor é um tipo de trocador de calor no qual o ar descartado é feito passar em contracorrente ou corrente cruzada com o ar de renovação, e desta forma ocorre um pré-tratamento deste ar de renovação (resfriando no verão e aquecendo no inverno).
- Uso de ciclo noturno: Outro recurso que pode ser empregado para reduzir o consumo do sistema de climatização é o ciclo noturno ou flushing noturno. Este recurso consiste em ventilar os ambientes durante o período noturno desocupado, tomando 100% de ar externo, caso as condições do ar externo sejam favoráveis (Por exemplo, a temperatura externa abaixo de 18°C e 4°C

abaixo da temperatura interior). O resfriamento da massa interna da edificação (móveis, paredes, entre outros) irá postergar o acionamento do sistema de climatização no dia seguinte, pois tal massa funcionará como um capacitor térmico.

- Uso de reset da temperatura da água gelada: A eficiência do ciclo de refrigeração do chiller depende das suas condições de operação, ou seja, temperatura de evaporação e temperatura de condensação. A eficiência aumenta com o aumento da temperatura de evaporação e/ou redução da temperatura de condensação. A temperatura de evaporação está relacionada à temperatura da água gelada na saída do chiller. O valor padrão (usual em projetos) para esta temperatura é $6,7^{\circ}\text{C}$, que geralmente é ajustada e configurada no equipamento para ser obtida durante todo o tempo de funcionamento do equipamento. Mas buscando reduzir o consumo de energia em dias com clima ameno, existe um recurso denominado reset da temperatura de saída da água gelada. Por meio desta funcionalidade o chiller opera com o valor de projeto ($6,7^{\circ}\text{C}$) somente quando a temperatura do ar externo é igual ou superior a $26,7^{\circ}\text{C}$, com o valor de $12,2^{\circ}\text{C}$ quando a temperatura do ar externo é igual ou menor do que $15,6^{\circ}\text{C}$, e varia linearmente entre estes dois valores ($6,7^{\circ}\text{C}$ e $12,2^{\circ}\text{C}$) de acordo com os valores limites de temperatura externa acima mencionados. Tais temperaturas limites (temperatura da água gelada e temperatura externa) também podem ser configuradas com valores customizados.
- Tipo de ventilação: Os ventiladores dos climatizadores podem apresentar vazão constante durante toda a sua operação (VAC – Vazão de Ar Constante), ou podem apresentar vazão variável (VAV – Vazão de Ar Variável) de acordo com a demanda por refrigeração dos ambientes atendidos por eles.
- Pressão dos ventiladores: A distribuição do ar climatizado nos ambientes da edificação é realizada através de redes de dutos de ar conectados aos climatizadores. O ventilador de cada climatizador deverá transferir ao ar a energia suficiente para que o mesmo escoe nos dutos e seja

insuflado nos ambientes com a velocidade projetada. Quanto mais longos e restritivos forem estes dutos, maior será a energia necessária. A característica do ventilador relacionada a este aspecto, utilizada para modelar o sistema, é a elevação de pressão total do ventilador na vazão de projeto.

- Tipo de bombeamento da água gelada: Existem diferentes configurações de bombeamento da água gelada, entre o(s) chiller(s) e os climatizadores, que podem ser utilizados em sistemas de água gelada. O sistema usualmente empregado consiste em dois circuitos: um circuito primário com vazão constante, que circula água através do(s) chiller(s), e um circuito secundário com vazão variável, que circula água através dos climatizadores. A modulação da vazão de água no circuito secundário, conforme a demanda por refrigeração nos ambientes (demanda nos climatizadores) é uma das vantagens desta configuração. Outros tipos de bombeamento considerados foram: sistema somente com circuito primário com vazão constante; e sistema somente com circuito primário com vazão variável.
- Pressão das bombas de água gelada: O bombeamento da água gelada é realizado por meio de bombas hidráulicas, e da mesma forma que os ventiladores, devem transferir energia suficiente a água para que esta possa circular através de todos os componentes do sistema. Quanto mais longas e restritivas forem as tubulações e os acessórios, maior será a energia necessária. A característica das bombas relacionada a este aspecto, utilizada para modelar o sistema, é a altura manométrica.
- Pressão das bombas de água de condensação: O bombeamento da água de condensação, empregada nos casos em que o chiller tem condensação a água, também é realizado por meio de bombas hidráulicas que transferem energia suficiente a água para que esta possa circular entre o chiller e a torre de resfriamento. A altura manométrica destas bombas foi a variável considerada para caracterizar tais equipamentos.
- Vazão de ar de renovação: Para garantir a qualidade do ar no interior dos ambientes, os climatizadores do sistema de climatização necessitam captar uma parcela de ar externo

para proporcionar uma renovação do ar interno. No Brasil, a parte 3 da NBR 16.401 (ABNT NBR 16.401, 2008) especifica os parâmetros básicos e os requisitos mínimos para a obtenção de qualidade aceitável de ar interior para conforto. A norma estipula a vazão mínima de ar exterior, a ser suprida pelo sistema, para promover a renovação do ar interior e manter a concentração dos poluentes em nível aceitável. Esta vazão mínima é calculada pela soma de duas parcelas: uma relacionada às pessoas e outra relacionada à área ocupada. Sendo assim, a norma apresenta recomendações de vazão em três níveis, para diversos tipos de edificações: comércio varejista, edifícios de escritórios, bancos, edifícios públicos, estabelecimentos de ensino, entre outros. O nível 1 corresponde ao valor mínimo, o nível 2 ao valor intermediário, e o nível 3 ao valor ideal. Nesta pesquisa, estes três níveis serão utilizados para definir os valores a serem empregados para esta variável.

- Chiller: As características adotadas para caracterizar o chiller foram o coeficiente de performance a plena carga (COP) e o IPLV, ambos definidos conforme AHRI Standard 550/590 (AHRI, 2011).

Para caracterizar o clima, indicadores climáticos foram avaliados, e com base no indicador de melhor desempenho, 18 arquivos climáticos foram selecionados e empregados para a criação da base de dados.

Para a escolha dos arquivos climáticos, empregados nesta pesquisa, um caso base de edificação de escritórios foi modelado, e a carga térmica integrada anual de refrigeração para este caso foi obtida para 20 cidades brasileiras. Duas cidades brasileiras com climas extremos (Macapá e Curitiba) foram somadas a mais 18 cidades com climas intermediários, para compor este conjunto inicial de 20 cidades. O programa computacional Energyplus foi utilizado com os respectivos arquivos climáticos INMET 2016, no formato EPW (*Energyplus Weather Data*), disponíveis no sítio eletrônico do LabEEE. A carga térmica integrada anual da edificação foi calculada através da somatória das energias horárias de resfriamento requeridas no evaporador do *chiller* (variável de saída do programa Energyplus denominada *Chiller Evaporator Cooling Energy*).

O primeiro indicador climático avaliado foi o *cooling degree hours* (CDH), o qual foi calculado para cada uma destas 20 cidades brasileiras de duas formas distintas: uma considerando a temperatura de todas as

8.760 horas presentes no arquivo climático, e outra considerando somente a temperatura das horas em que o sistema de climatização se encontrava em operação. O objetivo deste procedimento foi avaliar se o indicador, calculado com as horas de funcionamento do sistema de climatização, apresentava-se mais eficaz para representar o clima de cada cidade; e se o ganho obtido justificava o seu emprego. Para avaliar a influência da escolha da temperatura base, no cálculo do CDH de cada cidade, foram empregados valores de temperatura base entre 15 e 22°C, variando de 1 em 1°C.

Um modelo de regressão linear foi empregado para representar a relação entre a carga térmica integrada anual de refrigeração da edificação (caso base) e o correspondente valor de CDH. Os valores do índice estatístico R^2 (coeficiente de determinação – Equação 2) e do erro padrão (Equação 15) foram empregados para avaliar a qualidade deste ajuste.

$$\text{erro padrão} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - 2}} \quad (15)$$

Onde:

y = carga térmica integrada anual de resfriamento obtida por simulação;

\hat{y} = carga térmica integrada anual de resfriamento predita pela equação ajustada;

n = número total de dados;

Como a maioria das cidades brasileiras se caracteriza por altos valores de temperatura e umidade, foi desenvolvido nesta pesquisa um novo indicador climático utilizando a entalpia e a temperatura de bulbo seco. Com base na definição do CDH_H oriunda do trabalho de Shin e Do (2016) e do ELD (*enthalpy latent days*) dos trabalhos de Huang et al. (1987), Sailor e Muñoz (1997), Sailor (2001) e Krese et al. (2011), foi elaborado aqui o indicador que se chamou de *cooling enthalpy hours* (CEH), conforme mostra a Equação 16.

$$CEH = \sum_{n=1}^N \alpha \cdot (h_o - h_b)^+ \quad (16)$$

Onde:

CEH = *cooling enthalpy hours*;

h_o = entalpia do ar externo na hora considerada;

h_b = entalpia base;

N = número total de horas consideradas;

$$\alpha = 0 \text{ se } t < t_b \text{ ou } 1 \text{ se } t \geq t_b;$$

t_b = temperatura base.

O sinal positivo (+) sobrescrito na equação indica que somente são considerados na somatória os resultados positivos da subtração descrita entre parênteses.

O cálculo de CEH difere do cálculo de CDH_H , pela inclusão do termo alfa (α) na equação, que tem como objetivo introduzir a temperatura base no cálculo, visto que assim, somente serão consideradas as diferenças positivas de entalpia quando a temperatura externa for superior à temperatura base. Desta forma, considera que o sistema de climatização, por operar através da ação de um termostato, não estará em operação quando a temperatura externa for inferior à temperatura base, e o CEH não computará, nestes casos, a diferença entre a entalpia externa e à entalpia base.

Da mesma forma que para o CDH , o CEH foi calculado para o conjunto inicial das 20 cidades, de duas formas: considerando todas as horas do ano (8.760), e considerando somente as horas em que o sistema de climatização estava em funcionamento. E para avaliar a influência da escolha da entalpia base, foram empregados valores de entalpia base entre 34 e 52 kJ/kg, variando de 1 em 1 kJ/kg.

Um modelo de regressão linear também foi empregado para representar a relação entre a carga térmica integrada anual de refrigeração da edificação (caso base) e o correspondente valor de CEH, para as mesmas 20 cidades avaliadas anteriormente. O índice estatístico R^2 e o erro padrão foram empregados para verificar a qualidade deste ajuste.

Para validar o potencial do indicador climático aqui proposto, os cálculos de dois indicadores (CDH_H e CEH), bem como a simulação do caso base, foram realizados novamente para todos os 407 arquivos climáticos brasileiros disponíveis. O indicador CDH_H , que também emprega a entalpia em seus cálculos, foi considerado aqui para que seu desempenho fosse comparado com o do CEH. Um modelo de regressão linear foi empregado para representar a relação entre a carga térmica integrada anual de refrigeração e os valores dos indicadores CDH_H e CEH. O indicador com melhor resultado de desempenho foi escolhido para ser empregado nas etapas seguintes desta pesquisa.

A partir dos valores extremos do indicador escolhido (climas extremos), grupos foram criados, considerando que cada grupo corresponde a um intervalo fixo de valores numéricos deste indicador. Uma distribuição de frequência foi conduzida para verificar como cada grupo ficou representado, a partir das 407 cidades abordadas. E,

finalmente, um arquivo climático de cada um destes grupos foi escolhido para ser empregado nas simulações que geraram a base de dados. A escolha destes arquivos climáticos considerou dois critérios: o valor do seu respectivo indicador climático deveria estar próximo ao centro do intervalo numérico daquele grupo, e se possível, que a cidade fosse conhecida nacionalmente.

No processo de escolha do indicador climático, descrita anteriormente, os resultados de desempenho dos indicadores climáticos foram obtidos a partir da simulação de uma única edificação (caso base). Para avaliar o indicador climático escolhido nesta primeira etapa do trabalho (Etapa 1) em um âmbito mais genérico, novos estudos foram conduzidos após a obtenção dos dados das simulações de validação do metamodelo (Etapa 8). A partir destes dados, casos simulados para diferentes climas considerando outras edificações, que não o caso base, foram avaliados. O desempenho dos três indicadores estudados anteriormente (CDH, CDH_H e CEH) foi comparado.

3.1.2. Etapa 2 – Análise de sensibilidade

O objetivo desta etapa foi determinar quais são as características construtivas da edificação, que uma vez alteradas, proporcionavam alterações menos significativas nos perfis de carga térmica de refrigeração e conseqüentemente no desempenho do sistema de climatização de edifícios de escritórios, bem como determinar quais os parâmetros do sistema de climatização do tipo água gelada que apresentavam menor influência no consumo de energia. Sendo assim, tais variáveis tiveram seus valores fixos e somente as demais variáveis tiveram seus valores parametrizados para o desenvolvimento dos casos simulados durante o processo de criação da base de dados, reduzindo desta forma o número de casos.

As seguintes etapas foram conduzidas para a realização da análise de sensibilidade: determinação das faixas de valores das variáveis de entrada, simulação de uma amostra, e a realização da análise de sensibilidade a partir dos resultados da amostra simulada. Tais etapas são detalhadas abaixo.

3.1.2.1. Determinação dos valores das variáveis de entrada

O primeiro passo na análise de sensibilidade aplicada ao desempenho de edificações é determinar as variáveis que serão utilizadas para caracterizar a edificação e seus sistemas, bem como definir a faixa dos possíveis valores destas variáveis. Estas variáveis podem ser assumidas com distribuição de probabilidades uniforme ou

discreta. As faixas de valores buscaram representar intervalos aceitáveis fisicamente e possíveis de serem encontrados em edificações de escritórios. Para tanto, os trabalhos de Santana (2006), Carlo (2008), Melo (2012) e Versage (2015) serviram como referência para a definição de tais valores.

Como as variáveis já foram definidas na Etapa 1, a seguir são apresentadas as faixas de valores consideradas na análise de sensibilidade para cada variável:

- Largura do pavimento tipo, com distribuição uniforme entre os valores de 10 e 50 metros;
- Relação de aspecto entre o comprimento e a largura do pavimento tipo, com distribuição uniforme entre os valores de 1 a 6;
- Número de pavimentos da edificação, com distribuição discreta considerando os seguintes valores: 5, 10, 20, 30, 40 e 50;
- Percentual de abertura nas fachadas (WWR – Window Wall Ratio), idêntico nas quatro fachadas, com distribuição uniforme entre 0,15 e 0,95;
- Orientação solar da edificação, com distribuição uniforme entre 0 e 135°;
- Fator solar dos vidros, com distribuição uniforme entre 0,2 e 0,8;
- Transmitância térmica do material do vidro, com distribuição discreta com os valores: 1,7; 2,7 e 5,8 W/m².K;
- Absortância solar das paredes externas, com distribuição uniforme entre 0,2 e 0,8;
- Transmitância térmica das paredes externas, com distribuição uniforme entre 0,5 e 2,9 W/m².K;
- Capacidade térmica das paredes externas, com distribuição uniforme entre 40 e 270 kJ/m².K;
- Absortância solar da cobertura, com distribuição uniforme entre 0,2 e 0,8;
- Transmitância térmica da cobertura, com distribuição uniforme entre 0,5 e 3,65 W/m².K;
- Capacidade térmica da cobertura, com distribuição uniforme entre 30 e 250 kJ/m².K;
- Capacidade térmica das paredes internas, com distribuição uniforme entre 40 e 270 kJ/m².K;

- Infiltração de ar, com distribuição uniforme entre 0 e 0,75 trocas de ar por hora;
- Densidade de potência de iluminação, com distribuição uniforme entre 7,5 e 15 W/m²;
- Índice de ocupação, com distribuição uniforme entre 3 e 15 m²/pessoa;
- Perfil de uso da edificação, ou horário de funcionamento, com distribuição discreta com os valores: 8, 9, 10, 11, 12, 13, 14, 15 e 16 horas de funcionamento diárias somente nos dias de semana, conforme Figura 5;




Figura 5 – Possíveis horários de funcionamento nos dias de semana.

- Temperatura do termostato, com distribuição uniforme com valores entre 20°C e 24°C;
- Uso do ciclo economizador e recuperador de calor, com distribuição discreta com as seguintes opções: sistema com ciclo economizador e sem recuperador de calor, sistema sem ciclo economizador e com recuperador de calor, e sistema sem ciclo economizador e sem recuperador de calor;
- Uso de ciclo noturno, com distribuição discreta com as seguintes opções: sistema sem ciclo noturno, e sistema com ciclo noturno;
- Uso de reset da temperatura da água gelada, com distribuição discreta com as seguintes opções: sistema sem o emprego de reset da temperatura de água gelada, e

sistema com o emprego de reset da temperatura de água gelada;

- Tipo de ventilação, com distribuição discreta com as seguintes opções: sistema com vazão constante (VAC), e sistema com vazão variável (VAV);
- Pressão dos ventiladores (elevação de pressão total do ventilador), com distribuição uniforme entre os valores de 150 e 750 Pa;
- Tipo de bombeamento, com distribuição discreta com as seguintes opções: sistema com circuito primário com vazão constante + circuito secundário com vazão variável, sistema somente com circuito primário com vazão constante, e sistema somente com circuito primário com vazão variável;
- Pressão das bombas de água gelada (somatória da altura manométrica das bombas do circuito primário e do circuito secundário), com distribuição uniforme entre os valores de 250.000 e 850.000 Pa (quando o sistema possui circuitos primário e secundário, foi considerado que do valor total, 150.000 Pa é utilizado para o circuito primário e o restante para o circuito secundário);
- Pressão das bombas de água de condensação (altura manométrica da bomba de água de condensação), com distribuição uniforme entre os valores de 100.000 e 650.000 Pa;
- Vazão de ar de renovação, com distribuição discreta com as seguintes opções: Nível 1 da NBR 16.401 para escritórios – 2,5 l/s.pessoa e 0,3 l/s.m², Nível 2 da NBR 16.401 para escritórios – 3,1 l/s.pessoa + 0,4 l/s.m², e Nível 3 da NBR 16.401 para escritórios – 3,5 l/s.pessoa + 0,5 l/s.m²;
- Chiller, com distribuição discreta, considerando o emprego de 10 diferentes chillers, conforme Tabela 3 (buscou-se obter uma amostra representativa a partir dos chillers disponíveis na documentação do software EnergyPlus, mantendo-se a relação proporcional entre chiller a ar e a água, e também da faixa existente de valores de COP, nesta documentação);

Tabela 3 – Características dos *chillers* utilizados na análise de sensibilidade*.

Nome	Fabricante/Modelo	Tipo de condensação	COP	IPLV
Chiller 1	McQuay AGZ070D	a ar	2,8	4,0
Chiller 2	Carrier 30XA220	a ar	3,1	4,5
Chiller 3	Trane RTWA 383kW	a água	4,2	5,2
Chiller 4	Carrier 23XL 724kW	a água	4,7	6,4
Chiller 5	Trane RTHB 1051kW	a água	5,1	6,7
Chiller 6	Carrier 19XR 1403kW	a água	5,4	7,8
Chiller 7	Carrier 19EX 5148kW	a água	5,9	7,0
Chiller 8	York YT 2110kW	a água	6,3	7,6
Chiller 9	York YK 5465kW	a água	6,6	7,8
Chiller 10	York YK 5170kW	a água	6,9	8,2

*Os coeficientes das curvas de desempenho de tais equipamentos foram obtidos na documentação do Energyplus (*datasets: AirCooledChiller.idf, Chillers.idf*).

- Clima, com distribuição discreta, considerando 18 arquivos climáticos (Tabela 4) selecionados na etapa anterior.

Tabela 4 – Arquivos climáticos empregados nas simulações.

Grupo	Arquivo empregado
1	Petrópolis – RJ
2	Campos do Jordão – SP
3	Lagoa Vermelha – RS
4	Bagé – RS
5	São Paulo – SP
6	Porto Alegre – RS
7	Sorocaba – SP
8	Belo Horizonte – MG
9	Goiânia – GO
10	Rio de Janeiro – RJ
11	Governador Valadares – MG
12	Vitória – ES
13	Palmas – TO
14	Recife – PE
15	Natal – RN
16	Boa Vista – RR
17	São Luís – MA
18	Manaus - AM

A Tabela 5 apresenta, de forma resumida, as variáveis que foram utilizadas para caracterizar a edificação, o sistema de ar condicionado e o clima, e os respectivos valores adotados para a realização da análise de sensibilidade.

Tabela 5 – Variáveis utilizadas na análise de sensibilidade, e os seus respectivos valores.

Variável	Valores utilizados
Largura do pavimento tipo	10 a 50 m
Relação entre o comprimento e a largura do pavimento tipo	1 a 6
Número de pavimentos da edificação	5, 10, 20, 30, 40 e 50
Orientação solar da edificação	0 a 135°
Percentual de abertura nas fachadas	0,15 a 0,95
Fator solar dos vidros	0,2 a 0,8
Transmitância térmica do vidro	1,7; 2,7 e 5,8 W/m ² .K
Absortância solar das paredes externas	0,2 a 0,8
Transmitância térmica das paredes externas	0,5 a 2,9 W/m ² .K
Capacidade térmica das paredes externas	40 a 270 kJ/m ² .K
Absortância solar da cobertura	0,2 a 0,8
Transmitância térmica da cobertura	0,5 a 3,65 W/m ² .K.
Capacidade térmica da cobertura	30 a 250 kJ/m ² .K
Capacidade térmica das paredes internas	40 a 270 kJ/m ² .K
Infiltração de ar	0 a 0,75 trocas de ar por hora
Densidade de potência de iluminação	7,5 a 17,5 W/m ²
Índice de ocupação	3 a 15 m ² /pessoa
Horário de funcionamento	8, 9, 10, 11, 12, 13, 14, 15 e 16 horas diárias
Temperatura do termostato	20 a 24°C
Ciclo economizador/recuperador de calor	presente/ausente, ou ausente/presente, ou ausente/ausente
Ciclo Noturno	Ausente ou presente
Reset da temperatura da água gelada	Ausente ou presente
Tipo de ventilação	VAC ou VAV
Pressão dos ventiladores	150 a 750 Pa

(continua)

Tabela 5 – Variáveis utilizadas na análise de sensibilidade, e os seus respectivos valores.

(conclusão)

Variável	Valores utilizados
Tipo de bombeamento da água gelada	Primário constante / Secundário variável, ou Somente primário constante, ou Somente primário variável
Pressão das bombas de água gelada	250 a 850 kPa
Pressão das bombas de água de condensação	100 a 650 kPa
Vazão de ar de renovação	Nível 1 / Nível 2 / Nível 3
<i>Chiller</i>	10 <i>chillers</i> diferentes (Tabela 3)
Clima	18 arquivos climáticos (Tabela 4)

3.1.2.2. Simulação de uma amostra

Conforme descrito na revisão bibliográfica, o programa SIMLAB foi utilizado para a realização da análise de sensibilidade pelo método Sobol.

Os fatores de entrada no SIMLAB foram configurados como sendo as 30 variáveis de entrada definidas anteriormente (Tabela 5), empregando distribuição discreta ou uniforme conforme descrito no item 3.1.2.1. O tamanho da amostra para a realização da análise de sensibilidade pelo método Sobol é definida pela Equação 17 (SALTELLI et al., 2004).

$$Tamanho da amostra = (2.k + 2).N \quad (17)$$

Onde:

k = número de fatores (variáveis de entrada);

N = número representativo do tamanho da amostra requerida para computar uma estimativa simples;

O SIMLAB tem como opções para N os valores de 32, 64, 128, 256, 512, 1024 e 2048. Resultados preliminares com N=128 (amostra com 7.936 casos) indicaram a ocorrência de grande quantidade de números negativos nos resultados dos índices da análise de sensibilidade. Os valores negativos, segundo Saltelli et al. (2004), são devidos aos erros numéricos do processo de cálculo destes índices, e o acréscimo no tamanho da amostra reduz a probabilidade da ocorrência destes valores.

Sendo assim, optou-se pelo emprego do maior valor disponível para N (N=2048), resultando em uma amostra com 126.976 casos. Tal amostra é gerada pelo SIMLAB através da combinação de diferentes valores para os fatores de entrada.

Os 126.976 casos foram simulados com o emprego do programa de simulação EnergyPlus para a obtenção das seguintes variáveis de saída:

- Carga térmica integrada anual de refrigeração da edificação por metro quadrado de piso (kWh/m^2);
- Consumo anual de energia do sistema de climatização por metro quadrado de piso (kWh/m^2).

3.1.2.3. Realização da análise de sensibilidade

Uma vez obtidos os resultados das simulações dos 126.976 casos da amostra, tais resultados foram carregados no SIMLAB, para que os índices da análise de sensibilidade, pelo método Sobol, fossem calculados pelo programa. Tais índices são: índice de primeira ordem e índice de ordem total.

O índice de primeira ordem permitiu verificar quais as variáveis de entrada cuja variação apresenta maior impacto nos resultados de carga térmica integrada anual de refrigeração e consumo do sistema de ar condicionado. As variáveis com maior índice de primeira ordem são aquelas que apresentam maior influência nos resultados.

O índice de ordem total permitiu verificar quais as variáveis de entrada cuja variação apresenta menor impacto nos resultados de carga térmica integrada anual de refrigeração e consumo do sistema de ar condicionado. E assim, tais variáveis puderam ter o seu valor mantido fixo durante o processo de geração dos casos na fase de obtenção da base de dados. As variáveis com índice de ordem total próximo de zero são as variáveis que apresentam menor influência nos resultados.

3.1.3. Etapa 3 – Amostragem pelo método Hipercubo Latino

Ao concluir as etapas anteriores, foram definidos os parâmetros (construtivos, característicos do sistema de climatização e arquivos climáticos) cujos valores são parametrizados com o objetivo de criar os casos a serem simulados para constituir a base de dados. A combinação de todos estes parâmetros resultou em mais de quinhentos e vinte e seis trilhões de casos, cuja simulação é inviável. Para reduzir o número de casos a serem simulados, foi realizado um estudo amostral por Hipercubo Latino (MCKAY et al., 1979), da mesma forma que fizeram Westphal (2007), Melo (2012) e Versage (2015). Foram considerados

que os valores de cada parâmetro têm a mesma probabilidade de ocorrência.

O tamanho da amostra foi calculada, considerando a população infinita, para uma estimativa confiável da média populacional pela Equação 18 (ISRAEL, 1992):

$$n = \left(\frac{Z_{\alpha/2} \cdot \sigma}{E} \right)^2 \quad (18)$$

Onde:

n = tamanho da amostra;

$Z_{\alpha/2}$ = valor crítico que corresponde ao grau de confiança desejado;

α = desvio-padrão da variável em estudo;

E = margem de erro ou erro máximo da estimativa. Indica a diferença máxima entre a média amostral e a verdadeira média populacional.

3.1.4. Etapa 4 – Simulações

Para simular os casos resultantes da amostragem da etapa anterior adotou-se o programa EnergyPlus (versão 8.5). Um *script* foi desenvolvido em linguagem Python (versão 2.7.12) para manipular os objetos dos arquivos IDF (*Input Data File*), permitindo que o esforço de criação destes arquivos de entrada, bem como dos arquivos EPW (*EnergyPlus Weather Data*), fosse automatizado. As simulações foram realizadas com o uso do supercomputador denominado Santos Dumont (SDumont), que se encontra na sede do Laboratório Nacional de Computação Científica (LNCC) em Petrópolis-RJ. O SDumont possui capacidade instalada de processamento na ordem de 1,1 Petaflop/s, apresentando uma configuração híbrida de nós computacionais, no que se refere à arquitetura de processamento paralelo disponível. O SDumont possui um total de 18.144 núcleos de CPU, distribuídos em 756 nós computacionais (24 núcleos por nó). O conjunto de 250.000 casos foi simulado com o emprego de 30 nós computacionais, operando com processamento paralelo, rodando o EnergyPlus (versão 8.5) e 2 *scripts* em linguagem Python (versão 3.5.2). Um *script* foi desenvolvido com o objetivo de extrair os resultados de interesse dos arquivos de saída de cada simulação, e arquivá-los em um único arquivo no formato .csv (Comma-Separated Values). Outro *script* foi desenvolvido com o objetivo de extrair a quantidade de erros e warnings resultante em cada simulação, e arquivar estas informações em um arquivo.

Como resultados das simulações, foram armazenadas as seguintes grandezas:

- Número do caso simulado;
- Cidade considerada na simulação;
- Valor do indicador climático referente à cidade considerada;
- Área de piso total da edificação (m^2);
- Número de horas não atendidas (horas);
- Consumo anual de energia dos *chillers* por metro quadrado de área de piso (kWh/m^2);
- Consumo anual de energia dos ventiladores por metro quadrado de área de piso (kWh/m^2);
- Consumo anual de energia das bombas por metro quadrado de área de piso (kWh/m^2);
- Consumo anual de energia das torres de resfriamento por metro quadrado de área de piso (kWh/m^2);
- Consumo anual de energia total do sistema de climatização por metro quadrado de área de piso (kWh/m^2);
- Capacidade de cada *chiller* (TR);
- Carga térmica integrada anual de resfriamento por metro quadrado de área de piso (kWh/m^2);
- Máxima demanda de resfriamento por metro quadrado de área de piso (kW/m^2);
- Histograma de frequência da carga térmica de resfriamento, composto por vinte valores representando vinte classes de carga térmica (de 0 a 100%, onde cada classe representa um acréscimo de 5%).

3.2. FASE II – DESENVOLVIMENTO DO METAMODELO

A base de dados obtida na fase anterior foi empregada para o desenvolvimento de um modelo de predição empregando a técnica de redes neurais artificiais. O objetivo foi desenvolver um modelo capaz de estimar o consumo anual de energia do sistema de ar condicionado a partir do fornecimento de dados que caracterizem a carga térmica da edificação, o clima e o sistema de climatização. Foi utilizada a linguagem R (R, 2014), um programa computacional de acesso gratuito para cálculos estatísticos e matemáticos, no processo de modelagem preditiva.

As variáveis que afetam a resposta em um processo, e podem ser definidas ou medidas, são chamadas de variáveis preditoras ou variáveis independentes. As variáveis de interesse são chamadas de variáveis de resposta ou variáveis dependentes.

As características geométricas e construtivas da edificação, bem como o seu perfil de uso, associadas ao clima onde a mesma se encontra instalada, determinam a sua carga térmica por resfriamento e aquecimento. O modelo de predição foi concebido considerando que o usuário já dispõe dos valores de carga térmica da edificação, e que a partir destes valores e das informações do clima e das características do sistema de climatização, obterá o consumo deste sistema. Sendo assim, a carga térmica integrada anual de resfriamento por área de piso (kWh/m^2) foi empregada como variável independente (preditora) na construção do metamodelo, bem como quatro valores que representam o histograma de frequência da carga térmica de resfriamento (faixas de ocorrência: 0 a 25%, 25 a 50%, 50 a 75% e 75% a 100% da carga térmica máxima).

Além de influenciar a carga térmica da edificação, o clima também determina a eficiência dos equipamentos de climatização, especificamente o comportamento de consumo dos resfriadores de líquido (*chillers*) no caso de sistemas de ar condicionado do tipo água gelada. Desta forma, o indicador climático obtido na Etapa 1 foi empregado como uma das variáveis preditoras.

O metamodelo possui também variáveis preditoras que representam as características de maior influência do sistema de climatização, definidas através da análise de sensibilidade prevista na Etapa 2. Para a caracterização da eficiência do *chiller* foram empregadas como variáveis preditoras o COP a 100% e o IPLV (*Integrated Part Load Value*), ambos nas condições de teste da *AHRI Standard 550/590*. O IPLV é calculado através da Equação 19.

$$\text{IPLV} = 0,01.A + 0,42.B + 0,45.C + 0,12.D \quad (19)$$

Onde:

A = COP do *chiller* a 100% de carga;

B = COP do *chiller* a 75% de carga;

C = COP do *chiller* a 50% de carga;

D = COP do *chiller* a 25% de carga.

A seguir são descritas as principais etapas que compõem o método para a obtenção do metamodelo.

3.2.1. Etapa 5 – Pré-processamento

O primeiro passo em qualquer processo de construção de um metamodelo é entender os dados. Quando há muitas variáveis preditoras, é necessário entender melhor as características destas

variáveis e as relações entre elas. Estas características podem sugerir passos importantes e necessários de pré-processamento, que devem ser realizados antes da construção de um metamodelo.

Inicialmente, foram retirados da base de dados os casos em que o sistema de climatização foi subdimensionado, bem como aqueles que apresentaram erros de simulação. A variável intitulada “horas não atendidas” foi foco para a análise do dimensionamento do sistema de climatização. Tal variável indica o número de horas em que a edificação se encontra ocupada com o sistema de climatização operando, mas o setpoint não é atingido (ou seja, a temperatura interna permanece acima do valor de setpoint em 0,5°C ou mais, em pelo menos uma das zonas térmicas da edificação). O valor absoluto de horas não atendidas no período de um ano foi dividido pelo número total de horas em que o sistema de climatização operou com a edificação ocupada, resultando no chamado percentual de horas não atendidas. O RTQ-C (INMETRO, 2010), regulamento brasileiro para etiquetagem de edificações comerciais, determina que o sistema de climatização está corretamente dimensionado se o percentual de horas não atendidas for de no máximo 10%. Assim, os casos simulados que apresentaram valores acima deste valor foram retirados da base de dados.

Conforme mencionado na revisão bibliográfica, a busca por maneiras fáceis e rápidas de avaliar o desempenho de equipamentos e sistemas de climatização leva alguns engenheiros a utilizarem métodos baseados em um único índice (COP ou IPLV, por exemplo). Para demonstrar que tal procedimento não é eficaz, um estudo foi conduzido, a partir dos dados gerados pelas simulações, onde gráficos foram criados relacionando o consumo do sistema de climatização e a razão carga térmica/COP ou a razão carga térmica/IPLV.

A obtenção de um metamodelo pode ser dificultada devido às características dos dados, e por isso algumas transformações podem ser realizadas visando melhorar o processo (KUHN e JOHNSON, 2013). No pré-processamento, as seguintes transformações foram realizadas: adição de parâmetros substitutos, transformação dos valores para correção de assimetria, centralização e escalonamento dos dados. A seguir tais transformações são descritas.

Algumas variáveis utilizadas no processo de simulação foram substituídas visando buscar um melhor desempenho do processo de treinamento das redes neurais. Quando há um parâmetro de categoria (que não possui representação numérica) é recomendado que este parâmetro seja decomposto em variáveis mais específicas (KUHN e JOHNSON, 2013).

Uma variável apresenta distribuição simétrica quando apresenta o mesmo valor para a moda, a média e a mediana. Isto significa que a probabilidade de cair em ambos os lados da média da distribuição é aproximadamente igual. Uma distribuição é dita assimétrica à esquerda quando possui um grande número de pontos do lado esquerdo da distribuição comparado com o lado direito, e vice-versa para uma distribuição dita assimétrica à direita. As variáveis utilizadas como dados de entrada das simulações já apresentam distribuição homogênea devido ao processo de amostragem por Hipercubo Latino. No entanto, as variáveis que são resultados das simulações (carga térmica de refrigeração e consumo do sistema de climatização) foram analisadas quanto a sua distribuição e passaram por uma transformação para reduzir a assimetria dos dados. O método de transformação utilizado foi o Box-Cox (BOX e COX, 1964), que consiste na seguinte transformação indexada por um parâmetro denominado λ (Equação 20).

$$x^* = \begin{cases} \frac{x^\lambda - 1}{\lambda} & \text{se } \lambda \neq 0 \\ \log(x) & \text{se } \lambda = 0 \end{cases} \quad (20)$$

Todas as variáveis passaram pela transformação de centralização e escalonamento dos dados. Para centralizar uma variável, o seu valor médio é subtraído de todos os valores, resultando em uma nova variável com média igual a zero. De forma similar, para escalonar uma variável, cada valor da variável é dividido pelo seu desvio padrão, resultando em uma nova variável com desvio padrão unitário. Estas manipulações são geralmente utilizadas para melhorar a estabilidade numérica de alguns cálculos presente no processo de obtenção dos modelos (KUHN e JOHNSON, 2013).

3.2.2. Etapa 6 – Treinamento de modelos com diferentes tamanhos de amostra

Depois de entender os dados, o próximo passo foi construir e avaliar metamodelos, com o emprego de redes neurais artificiais, utilizando diferentes tamanhos de amostra (conjunto de treinamento).

Tamanhos de amostra foram calculados, através da Equação 5, para diferentes valores de $Z_{\alpha/2}$, de acordo com o grau de confiança desejado (90%, 95%, 99,0%, 99,5% e 99,9%). Uma rede neural com apenas uma camada interna de neurônios foi obtida para cada um destes tamanhos de amostra através do emprego da validação cruzada repetida 6 vezes com k-fold igual a 10. O número de neurônios na camada interna foi definida considerando a “regra de ouro” de utilizar 2/3 da soma dos nós da

camada de entrada e da camada de saída (PANCHAL et al., 2011). Os índices de desempenho de cada rede neural (R^2 , RMSE, NRMSE e tempo de processamento) foram calculados utilizando cada modelo para prever o consumo de energia do sistema de climatização de toda a base de dados, e não somente dos dados que ficaram fora da amostra. Estes resultados foram comparados para a determinação do tamanho de amostra a ser empregado nas etapas posteriores do trabalho.

O desenvolvimento dos metamodelos foi realizado com o emprego da linguagem R em um cluster computacional composto por 16 processadores Intel Xeon E7-4830 de 2,2GHz. O principal pacote (biblioteca contendo funções e dados) utilizado foi o Caret para R (KUHN, 2008), que possui ferramentas para tratamento de dados, pré-processamento de variáveis e seleção de configurações dos modelos.

3.2.3. Etapa 7 – Aprimoramento do metamodelo

O aprimoramento do metamodelo foi realizado através da variação do tamanho da camada interna (número de nós) da rede neural, e da alteração das variáveis preditoras que definem o desempenho do chiller e o histograma da carga térmica de resfriamento da edificação.

Na Etapa 6 foram utilizadas redes neurais com somente uma camada interna de neurônios. A quantidade de neurônios (nós) nesta camada interna foi definida como sendo igual ao valor de dois terços de N ($0,67 \times N$), que corresponde à soma da quantidade de variáveis independentes e dependentes. No processo de aprimoramento foram criados metamodelos com número de nós na camada interna nas proporções de 0,35; 0,5; 0,8; 0,95; 1,1; 1,25; 1,4; 1,55; 1,7; 1,85 e 2,0 vezes o valor de N . Os mesmos índices de desempenho empregados na etapa anterior (R^2 , RMSE, NRMSE e tempo de processamento) foram empregados para a avaliação e comparação destes metamodelos, e a análise dos resultados permitiu a definição da quantidade de neurônios a ser utilizada para a camada interna da rede neural. A rede neural obtida com esta quantidade de neurônios na camada interna foi denominada rede neural base, e representada pela sigla RNA 32. Uma análise dos erros percentuais entre os valores de consumo preditos por esta rede neural e os valores obtidos através da simulação foi conduzida buscando avaliar o desempenho da RNA, bem como identificar a ocorrência de erros maiores para alguma faixa específica de valores utilizados para cada variável de entrada.

Com relação às variáveis preditoras (nós de entrada), a arquitetura inicial do modelo de rede neural considerou as variáveis que caracterizam o sistema de climatização, o clima e a carga térmica da

edificação. Para caracterizar a carga térmica, foram definidas como variáveis predictoras a carga térmica integrada anual de resfriamento por área de piso, e o histograma desta carga térmica representado por quatro classes (*bins*) (0-25%, 25-50%, 50-75% e 75-100%). A influência da inclusão, exclusão ou alteração de algumas variáveis predictoras no desempenho do modelo foram avaliadas.

O primeiro estudo realizado consistiu em desenvolver uma rede neural onde não fosse empregada a carga térmica da edificação e seu histograma como variáveis de entrada, mas sim todas as variáveis que determinam a sua carga térmica e que foram empregadas no processo de criação da base de dados, a saber: largura da edificação, relação comprimento e largura, número de pavimentos, orientação solar, WWR, fator solar dos vidros, transmitância térmica dos vidros, infiltração de ar, DPI, ocupação, horário de funcionamento, temperatura do termostato. Assim, a arquitetura da nova rede neural incluiu 12 variáveis de entrada e excluiu cinco (carga térmica e quatro classes do histograma de frequência da carga térmica) em relação a rede neural base (que possuía 18 variáveis de entrada e uma de saída), resultando em uma rede neural composta por 25 variáveis de entrada e uma variável de saída. O objetivo deste estudo foi avaliar a diferença no desempenho da rede neural ao se empregar a carga térmica integrada anual e seu histograma (arquitetura mais simplificada para a rede neural), ao invés das características da edificação que geraram esta carga térmica, buscando validar o emprego da rede neural mais simplificada (rede neural base). Esta nova rede neural também foi treinada através de validação cruzada com 10 k-fold repetida 6 vezes. Diferentes tamanhos de camada interna foram avaliados para a definição do tamanho da rede (melhor desempenho). Os dados de desempenho (R^2 , RMSE e NRMSE) desta nova rede foram comparados aos dados de desempenho da rede neural base.

Outro estudo realizado consistiu em utilizar a arquitetura da rede neural base (18 variáveis de entrada e uma variável de saída), mas empregar somente os casos com *chillers* a ar para treinar uma nova rede (RNA 32_ar) e os casos com *chillers* a água para treinar outra rede (RNA 32_água). Desta forma, o desempenho desta estratégia (redes neurais distintas para cada tipo de *chiller*) pode ser avaliado.

Uma alteração analisada na rede neural base foi a substituição do valor do IPLV do chiller, pelos valores de COP a 25%, COP a 50% e COP a 75% de carga parcial, que compõe a equação de cálculo do IPLV (Equação 19). O tamanho da camada interna para esta nova arquitetura de rede foi determinado treinando redes com diferentes tamanhos de

camada interna e comparando os resultados de desempenho obtidos, da mesma forma realizada quando da obtenção da rede neural base. O desempenho desta nova rede neural, denominada RNA 35_COP, foi comparado com o desempenho da rede neural base (RNA32). O objetivo foi avaliar se haveriam ganhos de desempenho com o uso desta nova arquitetura de rede neural que justificassem a escolha desta rede como metamodelo final.

A influência do emprego dos valores do histograma da carga térmica de resfriamento como variáveis preditoras foi avaliada. Novas redes neurais foram treinadas com diferentes tamanhos de camada interna, sem o uso das quatro classes do histograma como variáveis preditoras. Novamente, os resultados da rede que apresentou o melhor desempenho entre estas novas redes (denominada RNA 29_sHIS) foi comparado com os da rede neural base. O objetivo foi avaliar qual a perda de desempenho obtida com esta simplificação na arquitetura da rede neural.

Ao final desta etapa obteve-se três redes neurais (RNA 32, RNA 35_COP e RNA 29_sHIS), dentre as quais uma será considerada como metamodelo final desta pesquisa. Para auxiliar nesta escolha, os erros percentuais de predição do consumo, obtidos com cada rede neural, foram calculados e apresentados em um gráfico de caixa (*boxplot*). O desempenho destas três redes também foi avaliado na predição de consumo de novos casos, conforme descrito a seguir.

3.2.4. Etapa 8 – Avaliação do metamodelo

A primeira avaliação, para testar a generalização do metamodelo, consistiu na realização de testes para valores de parâmetros não vistos. Novos casos foram simulados utilizando valores de parâmetros não utilizados no processo de criação da base de dados (Etapa 4), e redes neurais obtidas na Etapa 7 foram utilizadas para prever os valores de consumo de energia do sistema de climatização destes casos. Os índices de desempenho foram calculados a partir da comparação dos valores obtidos na simulação e os valores preditos pelas redes neurais, e os erros percentuais também foram calculados e apresentados em um diagrama de caixa (*boxplot*). Esta análise permitiu selecionar qual das redes neurais seria adotada como metamodelo final desta pesquisa.

A segunda avaliação teve como objetivo avaliar o desempenho do metamodelo ao prever o consumo de energia do sistema de climatização de edificações, para duas cidades que apresentam indicador climático semelhante, mas valores de radiação solar distintos. Os indicadores climáticos avaliados na Etapa 1 consideram, em seus

cálculos, somente a temperatura e a entalpia do ar. No entanto, a radiação solar é um fator determinante na obtenção da carga térmica de edificações, e terá maior influência quanto maior for a área envidraçada e/ou o fator solar do vidro. Entende-se que a radiação não terá influência no desempenho do metamodelo final, visto que a carga térmica integrada anual é uma variável de entrada deste metamodelo, e assim a influência da radiação já se encontra incorporada no modelo. Para contrapor, outro metamodelo (obtido na Etapa 7) que não utiliza a carga térmica como variável de entrada, mas sim as características da edificação, também teve seu desempenho avaliado para as duas cidades com perfis de radiação distintos. Portanto, novos casos foram simulados utilizando valores de parâmetros utilizados no processo de criação da base de dados (Etapa 4), e duas redes neurais (metamodelo final, e metamodelo da Etapa 7 que utiliza as características da edificação como variáveis de entrada) foram utilizadas para prever os valores de consumo de energia do sistema de climatização destes casos, para duas cidades com indicador climático semelhante e perfis de radiação distintos. Os índices de desempenho foram calculados a partir da comparação dos valores obtidos na simulação e os valores preditos pelas redes neurais, e os erros percentuais também foram calculados e apresentados em um diagrama de caixa (*boxplot*).

A seguir os resultados obtidos em cada etapa do método são apresentados e discutidos.

4. RESULTADOS E DISCUSSÕES

A seção 4.1 apresenta os resultados obtidos na Etapa 1 com a definição das variáveis de interesse, e em especial, a variável de caracterização do clima. A seção 4.2 apresenta os resultados da Etapa 2, que através de análise de sensibilidade, definiu quais as variáveis de menor influência nos resultados de carga térmica de resfriamento e de consumo do sistema de climatização. As seções 4.3 e 4.4 apresentam os resultados das Etapas 3 e 4, respectivamente, descrevendo o processo de amostragem dos casos a serem simulados, e a simulação deste casos. Os resultados do pré-processamento nos dados (Etapa 5) são apresentados na seção 4.5. Na seção 4.6, os resultados de desempenho dos modelos treinados com diferentes tamanhos de amostra (Etapa 6) são descritos. Da mesma forma, a seção 4.7 apresenta os resultados de desempenho para os modelos treinados na Etapa 7 do método. E, finalmente, a seção 4.8 apresenta os resultados obtidos no processo de predição de casos não vistos (Etapa 8) que resultaram na escolha do metamodelo final desta pesquisa.

4.1. DEFINIÇÃO DAS VARIÁVEIS

As variáveis para a caracterização da edificação e do sistema de climatização foram definidas quando da elaboração do método. A definição da variável para caracterizar o clima (indicador climático) seguiu os procedimentos descritos no método, cujos resultados são descritos a seguir.

Uma edificação (caso base) foi definida para que simulações pudessem ser realizadas com o objetivo de avaliar o desempenho de possíveis indicadores climáticos. As características deste caso base foram definidas e são apresentadas na Tabela 6.

A carga térmica integrada anual de refrigeração foi obtida através da soma dos valores da variável *Chiller Evaporator Cooling Energy*, disponíveis nos resultados das simulações realizadas com o programa computacional Energyplus. A carga térmica integrada anual de resfriamento e os consumos do sistema de climatização (*chiller*, bombas, ventiladores e torre de resfriamento) foram normalizados pela área de piso total da edificação, o que facilita a comparação destes resultados entre os casos simulados. A Tabela 7 apresenta os resultados para o caso base.

Tabela 6 – Características do caso base.

Característica	Valor	Observação
Dimensões do pavimento tipo	65 x 18 m	
Distância entre pisos	3 m	
Número de pavimentos	15	
Percentual de abertura nas fachadas (WWR)	0,5	Idêntico nas quatro fachadas
Fator solar dos vidros	0,82	Ausência de marquises e brises
Transmitância térmica do material do vidro	5,78 W/m ² .K	
Absortância solar das paredes externas	0,5	
Transmitância térmica das paredes externas	2,6 W/m ² .K	
Capacidade térmica das paredes externas	156 kJ/m ² .K	
Absortância solar da cobertura	0,3	
Transmitância térmica da cobertura	2,42 W/m ² .K	
Capacidade térmica da cobertura	253 kJ/m ² .K	
Capacidade térmica das paredes internas	60 kJ/m ² .K	
Infiltração de ar	0,5 trocas por hora	
Densidade de potência de iluminação	12,5 W/m ²	
Densidade de potência de equipamentos	16,5 W/m ²	
Índice de ocupação	8,5 m ² /pessoa	
Orientação solar da edificação	0°	Vetor normal ao comprimento alinhado com o Norte

(continua)

Tabela 6– Características do caso base.

(conclusão)

Característica	Valor	Observação
Perfil de uso da edificação, ou horário de funcionamento	11 horas	8 às 19 horas nos dias de semana, e sem funcionamento nos finais de semana
Arquivo climático	Rio de Janeiro	INMET 2016
Coefficiente de performance do <i>chiller</i> (COP)	3,0	Um único <i>chiller</i> a ar com curvas <i>default</i> do Energyplus
Altura manométrica da bomba primária	179.352 Pa	Vazão constante
Altura manométrica da bomba secundária	392.400 Pa	Vazão variável
Elevação de pressão total do ventilador	450 Pa	<i>Fancoil</i> com vazão constante, sem ciclo economizador, sem ciclo noturno e sem recuperador de calor
Renovação de ar	2,5 l/s.pessoa 0,3 l/s.m ²	NBR 16.401 – Nível 1 para escritórios
Setpoint de refrigeração	24°C	

Tabela 7 – Resultados de carga térmica, consumo e eficiência - caso base (Rio de Janeiro-RJ).

Carga térmica integrada anual de refrigeração	155,2 kWh/m ²
Consumo anual do <i>chiller</i>	62,9 kWh/m ²
Consumo anual das bombas	3,3 kWh/m ²
Consumo anual dos ventiladores	13,3 kWh/m ²
Consumo anual total do sistema de climatização	79,5 kWh/m ²
COP médio do <i>chiller</i>	2,47
COP global do sistema de climatização	1,95
Eficiência global do sistema de climatização	1,79 kW/TR
Capacidade do <i>chiller</i>	580,0 TR

Em todos os casos simulados, descritos neste capítulo, foi adotado o fator de 0,8 para o fator de dimensionamento do *chiller*. Ou seja, o valor empregado para a capacidade do *chiller* corresponde a 80% do valor que o Energyplus dimensionaria. Tal procedimento foi utilizado porque foi observado que o dimensionamento realizado pelo Energyplus busca atender casos extremos de carga que ocorre durante poucas horas durante o ano. Outro fator de dimensionamento utilizado no Energyplus foi o fator de dimensionamento de resfriamento igual a 1,25 (*cooling sizing factor* no objeto *Sizing:Parameters*).

Os resultados do caso base ilustram que do consumo total do sistema de climatização, neste caso *chiller* com condensação a ar, 4,2% é devido ao bombeamento da água gelada, 16,7% é devido à ventilação e 79,1% é devido ao *chiller*. O *chiller* apresentou um valor médio de coeficiente de performance (COP) igual a 2,47, inferior ao valor de 3,0 correspondente ao desempenho em plena carga sob condições padrões de teste, devido ao seu funcionamento em cargas parciais. Definindo-se como coeficiente global do sistema a relação entre a carga térmica integrada anual de refrigeração e o consumo total anual do sistema, tem-se para o caso base o valor igual a 1,95 (kW/kW), ou 1,79 kW/TR.

A Figura 6 apresenta o perfil de frequência de carga térmica onde é possível avaliar qual a ocorrência de cada percentagem de carga térmica durante a operação anual do sistema de climatização (histograma da carga térmica de refrigeração). Ocorreram dois picos com maior frequência, um onde a carga térmica de refrigeração corresponde a 45% do valor máximo com frequência de 9,5% das horas, e outro onde a carga térmica de refrigeração corresponde a 60% do valor máximo com frequência de 9,0% das horas. Como o *chiller* é dimensionado para atender a carga térmica máxima, tem-se, neste caso, que em mais de 50% do tempo o *chiller* encontra-se operando para atender uma carga térmica inferior a 50% de sua capacidade, e somente 6,2% operando próximo a sua capacidade máxima (carga térmica > 80%). Este comportamento evidencia que o consumo do *chiller* dependerá muito mais de sua eficiência em cargas parciais do que em plena carga.

Conforme previsto na Etapa 1 do método, uma análise foi conduzida com o objetivo de identificar um indicador climático para ser empregado na caracterização do clima, e a partir deste indicador, os arquivos climáticos, utilizados na criação da base de dados, foram escolhidos.

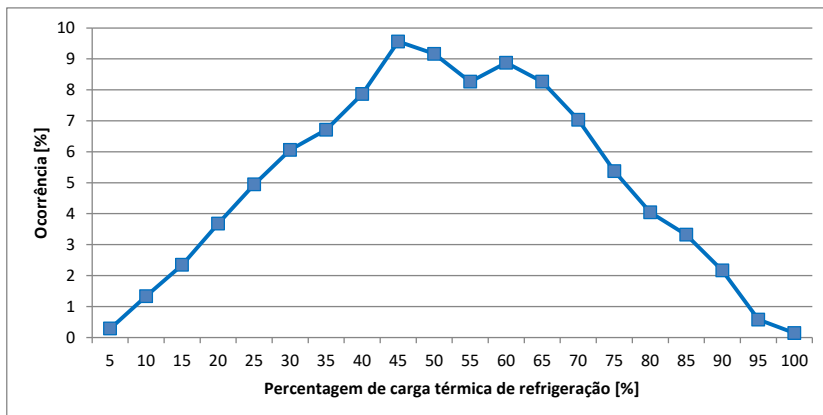


Figura 6 - Perfil de frequência de carga térmica - caso base (Rio de Janeiro-RJ).

Os resultados da carga térmica integrada anual de refrigeração e do indicador CDH (Equação 10 com temperatura base igual a 18°C) são apresentados na Tabela 8 para cada uma das 20 cidades brasileiras inicialmente analisadas. A Figura 7 apresenta o resultado da regressão linear utilizada para relacionar CDH e carga térmica integrada anual de resfriamento. O valor obtido para R^2 foi de 0,9428, e para o erro padrão foi 12,11 kWh/m².ano. Tais resultados ilustram que há uma forte correlação entre o CDH e a carga térmica integrada anual de refrigeração, ou seja, uma mesma edificação terá maiores valores para a carga térmica integrada anual de refrigeração quanto maior for o valor de CDH da cidade em que ela estiver localizada.

Tabela 8 – Resultados para CDH e carga térmica integrada anual de refrigeração para 20 cidades

Cidade	CDH [°C]	Carga térmica [kWh/m².ano]
Curitiba	11401	91,7
São Paulo	18729	118,3
Santa Maria	26677	100,1
Brasília	29493	148,2
Florianópolis	30758	118,0
Niterói	35434	133,7
Belo Horizonte	35528	134,4
Foz do Iguaçu	40991	140,9
Rio de Janeiro	47026	155,2

(continua)

Tabela 8– Resultados para CDH e carga térmica integrada anual de refrigeração para 20 cidades

(conclusão)

Cidade	CDH [°C]	Carga térmica [kWh/m ² .ano]
Campo Grande	50181	159,1
Gov. Valadares	53655	174,4
Rondonópolis	66656	202,9
Recife	67898	216,4
Macapá	68136	227,6
Salvador	68881	214,8
Cuiabá	73252	214,3
Palmas	77271	206,5
Boa Vista	78938	228,5
Belém	80237	242,8
Manaus	81288	241,6




Figura 7 – Regressão linear relacionando a carga térmica integrada anual de refrigeração e o indicador climático CDH de 20 cidades brasileiras (temperatura base=18°C).

O indicador CDH foi calculado novamente para diferentes valores de temperatura base (entre 15 e 22°C) com o objetivo de avaliar a sua influência nos resultados. A Tabela 9 apresenta o valor do coeficiente de

determinação (R^2) obtido em cada caso. A análise dos resultados mostra que o valor de R^2 não apresentou variação significativa, tendo o melhor resultado com o uso da temperatura base de 18°C.

Tabela 9 – Resultados de R^2 para a reta ajustada para relacionar carga térmica integrada anual de refrigeração e CDH com diferentes valores para temperatura base

Temperatura base	R^2
15°C	0,9360
16°C	0,9391
17°C	0,9416
18°C	0,9428
19°C	0,9417
20°C	0,9379
21°C	0,9301
22°C	0,9158

Buscando avaliar uma possível melhoria no indicador climático CDH, a forma de cálculo foi alterada considerando somente os horários de funcionamento do sistema de climatização (neste caso, considerando o horário de funcionamento e retirando os feriados, obteve-se 2.772 horas). Os cálculos de CDH para as 20 cidades foi realizado para a temperatura base de 18°C. A Figura 8 apresenta o resultado da regressão linear utilizada para relacionar a carga térmica integrada anual de resfriamento e o CDH calculado com as horas de funcionamento do sistema de climatização. O valor obtido para R^2 foi de 0,8989 e para o erro padrão foi 16,09 kWh/m².ano. Havia a expectativa de que ocorresse uma melhoria no ajuste ao se empregar somente os horários de funcionamento do sistema de climatização no cálculo do CDH, no entanto, ocorreu o contrário, pois o erro padrão aumentou 33%. Tal comportamento pode ser justificável pelo fato de que o conjunto das 8.760 horas é mais representativo para caracterizar o clima e sua influência sobre a carga térmica da edificação, visto que há, por exemplo, o efeito da inércia térmica da edificação, em que as condições climáticas, nos horários em que o sistema de climatização não está em funcionamento, afetam a carga térmica nas primeiras horas de operação do sistema de climatização.

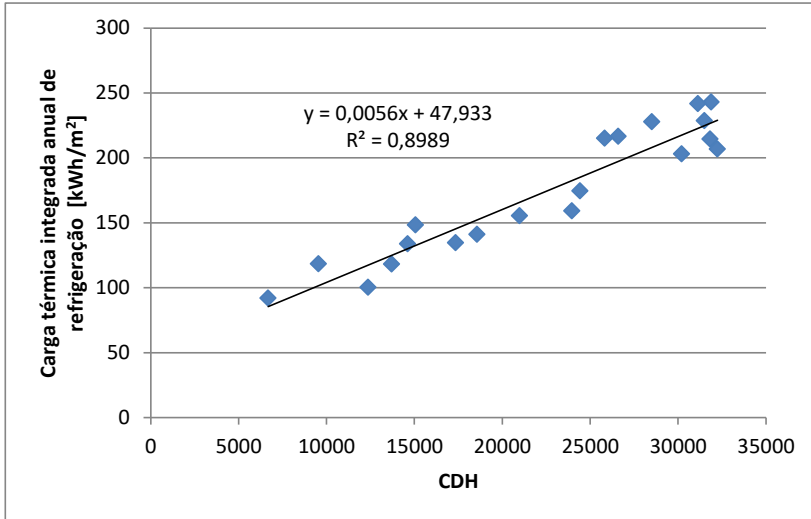


Figura 8 – Regressão linear relacionando a carga térmica integrada anual de refrigeração e o CDH de 20 cidades brasileiras, considerando somente as horas de funcionamento do sistema de climatização (temperatura base = 18°C).

O emprego da entalpia, ao invés da temperatura de bulbo seco, foi avaliado através do cálculo do indicador CEH (Equação 16). Primeiramente, foram utilizados nos cálculos os valores de entalpia de todas as 8.760 horas presentes no arquivo climático. O indicador CEH foi calculado para diferentes valores de entalpia base (entre 34 e 52 kJ/kg), sempre considerando a temperatura base de 18°C. A Tabela 10 apresenta o valor do coeficiente de determinação (R^2) obtido na regressão linear entre carga térmica integrada anual de refrigeração e CEH calculado para cada um dos valores de entalpia base. Para a entalpia base de 35 kJ/kg, que apresentou o maior valor de R^2 (0,9648), o erro padrão da regressão linear foi de 9,50 kWh/m².ano. A Figura 9 ilustra o ajuste obtido para este caso. Este resultado demonstra que o emprego do CEH como indicador climático é mais adequado do que o emprego do tradicional indicador CDH, uma vez que houve uma redução no valor do erro padrão.

Tabela 10 – Resultados de R^2 para a reta ajustada entre carga térmica integrada anual de refrigeração e CDH com diferentes valores para a entalpia base.

Entalpia base	R^2
34 kJ/kg	0,9647
35 kJ/kg	0,9648
36 kJ/kg	0,9646
37 kJ/kg	0,9643
38 kJ/kg	0,9637
39 kJ/kg	0,9629
40 kJ/kg	0,9619
41 kJ/kg	0,9606

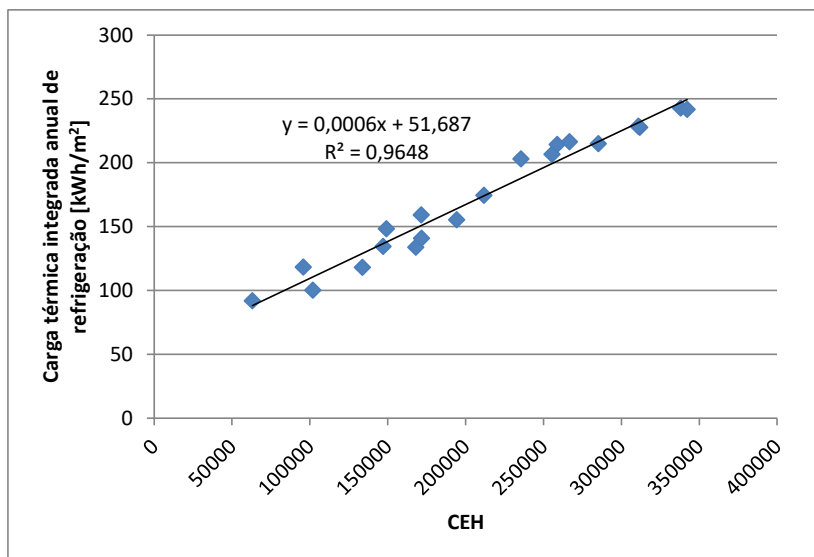


Figura 9 – Regressão linear relacionando a carga térmica integrada anual de refrigeração e o CEH de 20 cidades brasileiras (entalpia base = 35 kJ/kg e temperatura base = 18°C).

Novamente, a forma de cálculo do indicador foi alterada considerando somente os horários de funcionamento do sistema de climatização. Os cálculos de CEH para as 20 cidades foi realizada para a entalpia base de 35 kJ/kg e temperatura base de 18°C. A Figura 10 apresenta o resultado da regressão linear utilizada para relacionar a carga térmica integrada anual de resfriamento e o CEH calculado com as horas de funcionamento do sistema de climatização. O valor obtido para

R^2 foi de 0,9578 e para o erro padrão foi 10,39 kWh/m².ano. Portanto, da mesma forma que ocorreu com o CDH, tal estratégia não foi eficaz na tentativa de melhoria do indicador CEH, pois novamente o erro padrão aumentou (9,4%) com o emprego do CEH calculado somente das horas de funcionamento do sistema de climatização.

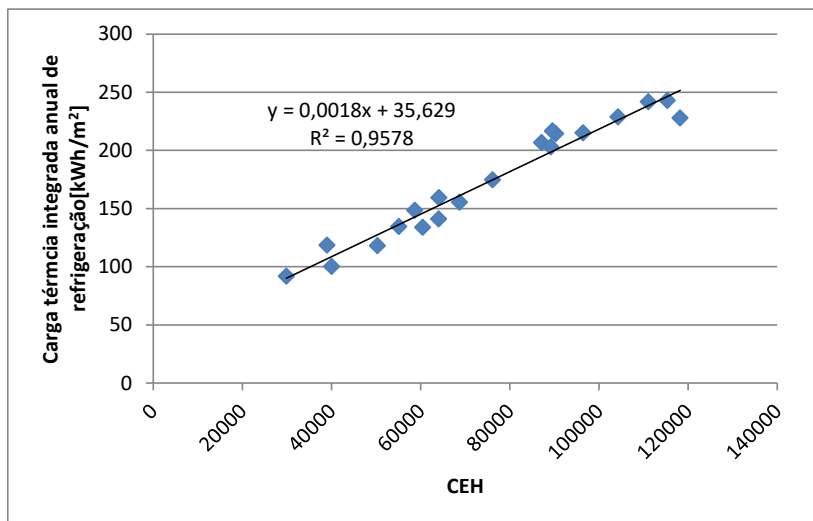


Figura 10 – Regressão linear relacionando a carga térmica integrada anual de refrigeração e o CEH de 20 cidades brasileiras, considerando somente as horas de funcionamento do sistema de climatização (entalpia base = 35 kJ/kg e temperatura base = 18°C).

Os valores elevados obtidos para o coeficiente de determinação (R^2 acima de 0,9) demonstram que há uma forte correlação entre os indicadores climáticos (CDH ou CEH) e a carga térmica integrada anual de resfriamento de uma edificação. Sendo que o CEH, que utiliza a entalpia em seu cálculo, apresentou uma melhor qualidade de ajuste para os valores preditos contra os valores obtidos por simulação. O erro padrão reduziu em cerca de 22% (de 12,11 para 9,50 kWh/m².ano) ao se empregar o CEH ao invés do CDH.

A variação nos valores base de entalpia e temperatura, empregados nas equações de CEH e CDH, permitiu concluir que tais valores não influenciam significativamente nos resultados da regressão linear empregada para relacionar tais indicadores com a carga térmica integrada anual de resfriamento, desde que os valores empregados estejam próximos aos valores de 37 kJ/kg e 18 °C, respectivamente.

O cálculo dos indicadores (CDH e CEH) considerando somente os valores da entalpia e/ou da temperatura nos horários em que o sistema de climatização encontra-se em funcionamento resultou na redução do desempenho destes indicadores. A razão disso pode ser o fato de que o emprego deste conjunto reduzido de valores (32% das horas presentes nos arquivos climáticos) não seja suficiente para representar adequadamente o clima e sua influência sobre a carga térmica da edificação. Portanto, o cálculo considerando todos os horários presentes no arquivo climático, que também é mais simplificado, foi adotado como padrão na definição do indicador CEH utilizado para representar o clima brasileiro.

Finalmente, o indicador CEH foi calculado para todas as 407 cidades brasileiras cujos arquivos climáticos (INMET 2016) estão disponíveis no sítio eletrônico do LabEEE, considerando o valor de 35 kJ/kg para a entalpia base, 18°C para a temperatura base, e todas as horas presentes no arquivo climático (8.760 h). A carga térmica integrada anual de refrigeração para a edificação modelo (caso base) também foi obtida através de simulação. O mesmo procedimento foi realizado considerando outro indicador climático que utiliza a entalpia em seus cálculos, o CDH_H (Equação 12).

A Figura 11 apresenta o gráfico que ilustra a correlação entre a carga térmica integrada anual de resfriamento e o indicador CDH_H , onde o valor obtido para R^2 foi 0,9285 e para o erro padrão foi 13,59 kWh/m².ano. A Figura 12 mostra a mesma correlação quando é empregado o indicador CEH. Os resultados confirmaram o desempenho superior do CEH como indicador climático visto que o valor de R^2 foi mais elevado (0,9459) e o erro padrão mais baixo (11,82 kWh/m².ano). Sendo assim, o indicador CEH foi escolhido com indicador climático para ser empregado no metamodelo desta pesquisa.

O menor valor de CEH calculado para estas 407 cidades foi 2.261 (Urubici-SC) e o maior 350.672 (Soure-PA). Considerando grupos formados a cada intervalo de 20.000 de CEH, foram obtidos 18 grupos para caracterizar a diversidade de climas brasileiros. A Figura 13 ilustra a distribuição em frequência das 407 cidades nestes 18 grupos.




Figura 11 – Regressão linear relacionando a carga térmica integrada anual de refrigeração e o CDH_H de 407 cidades brasileiras (entalpia base = 35 kJ/kg).




Figura 12 – Regressão linear relacionando a carga térmica integrada anual de refrigeração e o CEH de 407 cidades brasileiras (entalpia base = 35 kJ/kg e temperatura base = 18°C).

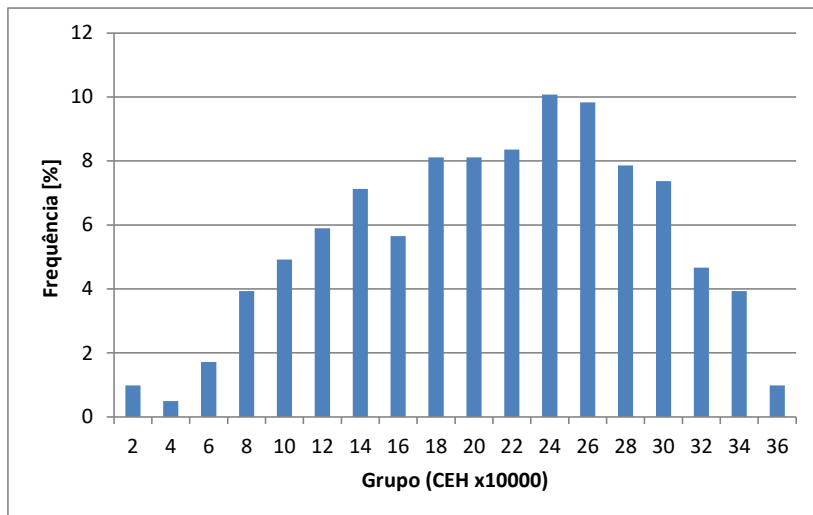


Figura 13 – Gráfico de frequência das 407 cidades nos 18 grupos criados com o CEH.

Um arquivo climático de cada um destes grupos foi escolhido para ser utilizado nas simulações que geraram a base de dados. A escolha destes arquivos climáticos considerou dois critérios: o valor de CEH desta cidade deveria estar próximo ao centro do intervalo numérico de CEH daquela zona, e se possível, que a cidade fosse conhecida nacionalmente. Na Tabela 11 encontram-se listadas as 18 cidades escolhidas.

Visto que o cálculo de CEH é realizado a partir de uma somatória de diferenças de entalpia de um arquivo climático, valores semelhantes de CEH podem ser obtidos a partir de climas com distribuição de frequência de entalpia distinta. Mesmo assim os resultados demonstraram que o indicador CEH é eficaz para relacionar o clima com a carga térmica integrada anual por resfriamento. Trabalhos futuros poderão investigar formas de caracterizar a diferença entre estes climas que apresentam valores semelhantes de CEH.

Tabela 11 – Cidades escolhidas para caracterizar a diversidade do clima brasileiro.

Grupo	Cidade representante	CEH [kJ/kg]
1	Petrópolis - RJ	12.217
2	Campos do Jordão - SP	34.190
3	Lagoa Vermelha – RS	50.577
4	Bagé – RS	69.614
5	São Paulo – SP	93.780
6	Porto Alegre - RS	112.434
7	Sorocaba - SP	130.992
8	Belo Horizonte – MG	147.155
9	Goiânia - GO	170.751
10	Rio de Janeiro – RJ	194.336
11	Governador Valadares – MG	211.805
12	Vitória – ES	229.685
13	Palmas – TO	255.547
14	Recife - PE	266.710
15	Natal – RN	291.197
16	Boa Vista – RR	310.958
17	São Luís – MA	332.020
18	Manaus – AM	342.270

As demais etapas do presente trabalho foram desenvolvidas considerando o CEH como indicador climático, pois tal indicador apresentou melhor desempenho conforme resultados descritos acima. Tais resultados foram obtidos utilizando sempre uma única edificação (caso base - Tabela 6). Ao final da última etapa do trabalho (Etapa 8), os dados gerados pelas simulações permitiram avaliar o desempenho dos indicadores climáticos para outras edificações, que não a edificação modelo (caso base). Por conveniência, optou-se por apresentar aqui tais resultados, que cronologicamente foram obtidos somente após a Etapa 8.

A partir das simulações realizadas na Etapa 8 foram coletados resultados de 28 casos (casos resultantes da parametrização das características da edificação e do clima, bem como do processo de amostragem por Hipercubo Latino, realizados naquela etapa), e uma regressão linear foi empregada para representar a relação entre a carga térmica integrada anual de refrigeração da edificação e o indicador climático. Três foram os indicadores climáticos avaliados, a saber: CDH, CDH_H e CEH. Em todos estes 28 casos, a edificação apresenta 40 pavimentos, geometria retangular, e distância entre pisos igual a 3

metros. As paredes externas têm transmitância térmica igual a $2,6 \text{ W/m}^2\cdot\text{K}$, capacidade térmica de $145 \text{ kJ/m}^2\cdot\text{K}$, e absorvância solar de $0,4$. As paredes internas tem capacidade térmica de $145 \text{ kJ/m}^2\cdot\text{K}$. A cobertura tem transmitância térmica igual a $1,93 \text{ W/m}^2\cdot\text{K}$, capacidade térmica de $106 \text{ kJ/m}^2\cdot\text{K}$, e absorvância solar de $0,5$. O setpoint empregado para o sistema de climatização foi 23°C , e a taxa de infiltração de ar é de $0,37$ trocas de ar por hora. A Tabela 12 apresenta os valores das seguintes características para cada um dos 28 casos: dimensões da edificação, percentual de abertura nas fachadas (WWR), orientação solar da edificação (OS), fator solar dos vidros (FS), densidade de potência de iluminação (DPI), taxa de ocupação (IOc), e o horas diárias de funcionamento diário durante os dias de semana.

Tabela 12 – Características das edificações nos 28 casos analisados.

Caso	Dim. [m]	WWR	OS [°]	FS	DPI [W/ m²]	IOc [m²/ pesso a]	Horário de func. [horas /dia]
1	20x35	0,25	22,5	0,27	8,75	5,0	9
2	20x35	0,65	22,5	0,27	8,75	5,0	9
3	20x35	0,25	22,5	0,57	8,75	5,0	9
4	20x35	0,25	22,5	0,27	13,75	5,0	9
5	20x35	0,25	22,5	0,27	8,75	13,0	9
6	20x35	0,25	22,5	0,27	8,75	5,0	13
7	20x35	0,25	112,5	0,27	8,75	5,0	9
8	20x95	0,25	22,5	0,27	8,75	5,0	9
9	20x95	0,65	22,5	0,27	8,75	5,0	9
10	20x95	0,25	22,5	0,57	8,75	5,0	9
11	20x95	0,25	22,5	0,27	13,75	5,0	9
12	20x95	0,25	22,5	0,27	8,75	13,0	9
13	20x95	0,25	22,5	0,27	8,75	5,0	13
14	20x95	0,25	112,5	0,27	8,75	5,0	9
15	40x70	0,25	22,5	0,27	8,75	5,0	9
16	40x70	0,65	22,5	0,27	8,75	5,0	9
17	40x70	0,25	22,5	0,57	8,75	5,0	9
18	40x70	0,25	22,5	0,27	13,75	5,0	9
19	40x70	0,25	22,5	0,27	8,75	13,0	9
20	40x70	0,25	22,5	0,27	8,75	5,0	13
21	40x70	0,25	112,5	0,27	8,75	5,0	9

(continua)

Tabela 12– Características das edificações nos 28 casos analisados.

(conclusão)

Caso	Dim. [m]	WWR	OS [°]	FS	DPI [W/ m ²]	IOc [m ² / pesso a]	Horário de func. [horas /dia]
22	40x190	0,25	22,5	0,27	8,75	5,0	9
23	40x190	0,65	22,5	0,27	8,75	5,0	9
24	40x190	0,25	22,5	0,57	8,75	5,0	9
25	40x190	0,25	22,5	0,27	13,75	5,0	9
26	40x190	0,25	22,5	0,27	8,75	13,0	9
27	40x190	0,25	22,5	0,27	8,75	5,0	13
28	40x190	0,25	112,5	0,27	8,75	5,0	9

A Tabela 13 apresenta os valores de erro padrão obtidos quando uma correlação linear, entre a carga térmica integrada anual de refrigeração e cada indicador climático, é empregada. Estes resultados mostram que o indicador CEH tem desempenho melhor do que os indicadores CDH e CDH_H, visto que os valores de erro padrão reduziram 46% em média quando o CDH_H é usado no lugar do CDH, e reduziram 29% em média quando o CEH é utilizado no lugar do CDH_H.

Tabela 13 – Valores de erro padrão obtidos nas regressões lineares que relacionam a carga térmica integrada anual de refrigeração e os indicadores climáticos CDH, CDH_H e CEH.

	Erro padrão				Erro padrão		
	CDH	CDH _H	CEH		CDH	CDH _H	CEH
Caso 1	13,91	11,08	8,14	Caso 8	14,63	8,22	5,57
Caso 2	13,83	9,79	7,45	Caso 9	12,22	8,81	6,73
Caso 3	19,52	12,98	10,81	Caso 10	16,76	9,99	7,31
Caso 4	15,47	10,02	8,06	Caso 11	15,59	8,49	6,36
Caso 5	8,83	9,74	7,48	Caso 12	10,45	8,51	6,53
Caso 6	24,85	12,16	7,17	Caso 13	19,22	9,40	5,33
Caso 7	13,28	9,93	7,91	Caso 14	16,41	9,83	7,99

(continua)

Tabela 13 – Valores de erro padrão obtidos nas regressões lineares que relacionam a carga térmica integrada anual de refrigeração e os indicadores climáticos CDH, CDH_H e CEH.

(conclusão)

	Erro padrão				Erro padrão		
	CDH	CDH_H	CEH		CDH	CDH_H	CEH
Caso 15	13,75	4,92	3,73	Caso 22	13,36	5,19	2,96
Caso 16	18,14	7,72	5,21	Caso 23	14,37	4,86	2,90
Caso 17	14,35	7,61	5,64	Caso 24	16,76	6,18	4,41
Caso 18	14,77	6,55	4,76	Caso 25	8,25	1,45	1,13
Caso 19	10,82	7,28	5,57	Caso 26	10,50	6,38	4,43
Caso 20	26,15	6,23	4,07	Caso 27	19,29	5,37	3,86
Caso 21	16,81	5,84	4,61	Caso 28	10,25	3,49	1,53

Portanto, os resultados obtidos com outras edificações, que não o caso base, mostraram novamente que o CEH tem desempenho superior quando comparado aos demais indicadores avaliados (CDH e CDH_H). Tal fato, que somente pode ser verificado na etapa final do trabalho, consolidou a escolha do CEH como indicador climático realizado na Etapa 1, e mostrou o potencial que tal indicador possui para ser empregado em trabalhos futuros.

4.2. ANÁLISE DE SENSIBILIDADE

Os índices do método Sobol (índice de primeira ordem e índice de ordem total) foram obtidos com o programa computacional SIMLAB, para cada variável de entrada, a partir dos resultados obtidos nas simulações desta etapa (126.976 casos).

A Tabela 14 apresenta os valores dos índices de primeira ordem correspondentes à influência da variação de cada uma das 30 variáveis nos resultados de carga térmica integrada anual de resfriamento da edificação, e nos resultados dos quatro valores do histograma de frequência da carga térmica.

Tabela 14 – Índices de primeira ordem relacionando as variáveis de entrada e a carga térmica de refrigeração

ÍNDICES DE PRIMEIRA ORDEM - SOBOL	Carga térmica anual	Histograma de frequência-carga térmica			
		25%	50%	75%	100%
Largura do pavimento tipo	0,01431	0,01223	0,02298	0,01783	0,02283
Relação entre comprimento e largura do pavimento tipo	0,00047	0,00031	0,00216	-0,00119	0,00362
Número de pavimentos da edificação	-0,00009	0,00133	0,00215	0,00200	0,00007
Orientação solar	0,00026	0,00138	0,00267	0,00257	0,00185
Percentual de abertura nas fachadas	0,01050	0,00246	0,01314	0,00526	0,00600
Fator solar dos vidros	0,01731	-0,00248	0,01362	0,00882	0,00303
Transmitância térmica dos vidros	-0,00072	0,00187	0,00274	-0,00079	-0,00190
Absortância solar das paredes externas	0,00001	0,00019	0,00048	0,00157	0,00179
Transmitância térmica das paredes externas	-0,00015	-0,00022	0,00074	0,00080	0,00354
Capacidade térmica das paredes externas	-0,00003	0,00016	0,00022	0,00042	0,00051
Absortância solar da cobertura	-0,00065	0,00004	-0,00170	-0,00124	-0,00011
Transmitância térmica da cobertura	0,00001	-0,00038	0,00123	0,00003	-0,00023
Capacidade térmica da cobertura	-0,00003	0,00013	0,00175	0,00108	-0,00118
Capacidade térmica das paredes internas	-0,00013	0,00009	-0,00113	-0,00088	0,00020
Infiltração de ar	0,00081	0,00700	0,01495	-0,00196	0,00215
Densidade de potência de iluminação	0,00461	0,00202	0,00402	0,00386	0,00285
Índice de ocupação	0,25621	0,01527	0,12738	0,08724	0,12345
Horário de funcionamento	0,13394	-0,00004	-0,00057	-0,00272	0,02144
Clima	0,40575	0,47290	0,21583	0,47861	0,09238
Temperatura do termostato	0,03225	0,01116	0,01733	0,02295	0,02244
Ciclo economizador/recuperador de calor	0,00684	0,12833	0,04360	0,01057	0,00683
Ciclo noturno	0,00000	0,00005	-0,00005	-0,00003	0,00004

(continua)

Tabela 14 – Índices de primeira ordem relacionando as variáveis de entrada e a carga térmica de refrigeração

(conclusão)

ÍNDICES DE PRIMEIRA ORDEM - SOBOL	Carga térmica anual	Histograma de frequência-carga térmica			
		25%	50%	75%	100%
Reset da temperatura da água gelada	-0,00053	0,00021	0,00112	0,00371	0,00974
Tipo de ventilação	-0,00127	0,01641	0,07214	0,00609	0,05181
Pressão dos ventiladores	0,00868	0,00195	0,00594	0,00566	0,00410
Tipo de bombeamento da água gelada	0,00011	0,00014	0,00142	-0,00038	0,00482
Pressão das bombas de água gelada	-0,00001	-0,00003	0,00021	0,00027	-0,00007
Pressão das bombas de água de condensação	0,00000	0,00000	0,00000	0,00000	0,00000
Vazão de ar de renovação	-0,00056	-0,00019	0,00110	0,00297	0,00341
Chiller	-0,00009	0,00125	0,00461	0,00321	0,00164

O índice de primeira ordem permite verificar quais as variáveis que apresentam maior influência nos resultados, pois quanto maior for o valor deste índice maior é a influência. Sendo assim, a análise dos valores apresentados na Tabela 14 permite concluir que dentre as 30 variáveis analisadas, as que apresentam maior influência na carga térmica integrada anual de resfriamento são o clima, o índice de ocupação e o horário de funcionamento (índices grifados em amarelo). O clima se mostrou a variável de maior influência devido a grande amplitude entre as condições climáticas extremas presentes no Brasil, ou seja, uma mesma edificação localizada em Curitiba apresentará uma carga térmica de refrigeração totalmente distinta se estiver localizada em Macapá, por exemplo. O índice de ocupação em escritórios afeta significativamente a carga térmica, pois além de determinar a parcela da dissipação de calor dos ocupantes, também determina a quantidade de equipamentos (computadores/impressoras) que irão gerar calor. O horário de funcionamento define o tempo em que o sistema de climatização opera, afetando assim a carga térmica integrada anual de refrigeração. A faixa de valores empregados na análise de sensibilidade, para o horário de funcionamento, abordou valores desde 8 até 16 horas diárias, o que contribuiu para a maior influência desta variável na carga térmica de resfriamento.

Observando os valores de índice de primeira ordem acima de 0,10, verifica-se que o clima, o índice de ocupação e o uso de ciclo

economizador/recuperador de calor são as variáveis que apresentaram maior influência no histograma de frequência da carga térmica de refrigeração (índices grifados em laranja). As justificativas para que o clima e o índice de ocupação apresentem tal influência são as mesmas já descritas anteriormente. O uso de ciclo economizador/recuperador de calor, por sua vez, interfere na carga térmica de refrigeração da edificação por reduzir a necessidade de refrigeração por parte dos climatizadores, utilizando ar externo em condições favoráveis (ciclo economizador) ou recuperando energia que seria perdida no ar exaurido (recuperador de calor).

A Tabela 15 apresenta os valores dos índices de primeira ordem correspondentes à influência da variação de cada uma das 30 variáveis nos resultados de consumo do sistema de climatização. Para cada um dos casos simulados, além do consumo anual total, foram obtidos os consumos anuais de cada componente do sistema: *chiller*, ventiladores, bombas e torre de resfriamento.

Tabela 15 – Índices de primeira ordem relacionando as variáveis de entrada e o consumo de energia do sistema de climatização

ÍNDICES DE PRIMEIRA ORDEM - SOBOL	consumo total	consumo chiller	consumo vent.	consumo bombas	consumo torre
Largura do pavimento tipo	0,01177	0,01187	0,00206	-0,00033	0,01125
Relação entre comprimento e largura do pavimento tipo	-0,00140	0,00013	-0,00261	0,00028	0,00048
Número de pavimentos da edificação	0,00023	0,00004	0,00035	0,00075	0,00008
Orientação solar	0,00026	0,00019	-0,00028	0,00001	-0,00014
Percentual de abertura nas fachadas	0,00622	0,00590	0,00295	0,00013	0,00356
Fator solar dos vidros	0,01212	0,01116	0,00421	0,00134	0,00874
Transmitância térmica dos vidros	0,00049	-0,00046	0,00099	-0,00044	-0,00039
Absortância solar das paredes externas	0,00023	0,00034	0,00003	-0,00006	-0,00001
Transmitância térmica das paredes externas	-0,00017	-0,00002	-0,00024	-0,00007	-0,00021
Capacidade térmica das paredes externas	0,00001	-0,00001	-0,00007	-0,00023	-0,00009
Absortância solar da cobertura	-0,00052	-0,00061	-0,00008	-0,00011	-0,00039

(continua)

Tabela 15– Índices de primeira ordem relacionando as variáveis de entrada e o consumo de energia do sistema de climatização (conclusão)

ÍNDICES DE PRIMEIRA ORDEM - SOBOL	consumo total	consumo chiller	consumo vent.	consumo bombas	consumo torre
Transmitância térmica da cobertura	0,00008	0,00002	0,00001	0,00015	0,00001
Capacidade térmica da cobertura	0,00016	0,00004	0,00018	-0,00013	0,00004
Capacidade térmica das paredes internas	-0,00024	-0,00013	-0,00021	0,00012	0,00006
Infiltração de ar	-0,00017	-0,00002	-0,00057	-0,00032	0,00238
Densidade de potência de iluminação	0,00447	0,00333	0,00236	0,00145	0,00147
Índice de ocupação	0,25462	0,19692	0,11770	0,24423	0,03449
Horário de funcionamento	0,09039	0,09148	0,02402	0,02730	0,02772
Clima	0,15112	0,27247	0,00142	0,03347	0,43402
Temperatura do termostato	0,05632	0,01727	0,07724	0,00341	0,01000
Ciclo economizador/recuperador de calor	-0,00020	0,00145	-0,00007	0,00069	0,00528
Ciclo noturno	-0,00028	0,00000	0,00100	0,00002	0,00000
Reset da temperatura da água gelada	0,00005	0,00019	-0,00005	-0,00269	-0,00002
Tipo de ventilação	0,07820	-0,00344	0,31624	0,00509	0,00261
Pressão dos ventiladores	0,10027	0,00493	0,30582	0,00125	0,00253
Tipo de bombeamento da água gelada	0,00051	0,00006	0,00000	0,11943	-0,00028
Pressão das bombas de água gelada	0,00004	0,00001	0,00000	0,06472	-0,00003
Pressão das bombas de água de condensação	-0,00127	0,00000	0,00000	0,10473	-0,00022
Vazão de ar de renovação	-0,00018	0,00002	-0,00004	0,00038	-0,00132
Chiller	0,09318	0,21129	0,00009	0,22457	0,19985

A análise dos valores apresentados na Tabela 15 permite concluir que dentre as 30 variáveis analisadas, as três que apresentam maior influência no consumo total do sistema de climatização são o índice de ocupação, o clima, e a pressão dos ventiladores (índices grifados em amarelo). O clima e o índice de ocupação são as variáveis de maior influência sobre o consumo porque são aquelas que têm a maior

influência sobre a carga térmica de refrigeração, conforme já verificado anteriormente. E dentre as variáveis que caracterizam o sistema de climatização, a pressão dos ventiladores apresentou maior influência sobre o consumo, seguida pela variável *chiller* e “tipo de ventilação” (VAC ou VAV). Sendo que as variáveis “tipo de ventilação” e “pressão dos ventiladores” apresentam maior influência sobre o consumo de ventiladores, enquanto as variáveis “tipo de bombeamento” e “pressão das bombas de água de condensação” apresentam maior influência sobre o consumo das bombas. A variável *chiller* apresenta forte influência sobre o consumo do *chiller*, bombas e torre, o que se justifica seja pela diferença de eficiência entre os equipamentos ou pelo tipo de condensação dos equipamentos (a ar ou a água).

A Tabela 16 apresenta os valores dos índices de ordem total correspondentes à influência da variação de cada uma das 30 variáveis nos resultados de carga térmica integrada anual de resfriamento da edificação, e nos resultados dos quatro intervalos do histograma de carga térmica.

O índice de ordem total permite verificar quais as variáveis que apresentam menor influência nos resultados, pois quanto mais próximo de zero for este valor, menor é a influência. Este é o índice de maior interesse da presente análise, visto que o objetivo foi identificar quais as variáveis que apresentavam menor influência nos resultados, e cujos valores puderam ser mantidos fixos no processo de criação da base de dados. A análise dos valores apresentados na Tabela 16 permite concluir que dentre as 30 variáveis analisadas, as que apresentam menor influência na carga térmica integrada anual de resfriamento (índice < 0,0009, grifados em azul) são 16 variáveis, a saber: o número de pavimentos, a orientação solar, a transmitância térmica dos vidros, a absorptância solar das paredes externas, a transmitância térmica das paredes externas, a capacidade térmica das paredes externas, a absorptância da cobertura, a transmitância térmica da cobertura, a capacidade térmica da cobertura, a capacidade térmica das paredes internas, o ciclo noturno, o reset de temperatura da água gelada, o tipo de bombeamento, a pressão das bombas de água gelada, a pressão das bombas de água de condensação e o *chiller*. Quando se analisam os índices de ordem total para o histograma de carga térmica verifica-se que as variáveis referentes ao número de pavimentos, orientação solar e transmitância térmica dos vidros não apresentam o mesmo baixo índice apresentado para a carga térmica integrada anual (índices grifados em verde, índice > 0,01).

Tabela 16 – Índices de ordem total relacionando as variáveis e a carga térmica de refrigeração

ÍNDICES DE ORDEM TOTAL- SOBOL	Carga térmica anual	Histograma de frequência-carga térmica			
		25%	50%	75%	100%
Largura do pavimento tipo	0,03038	0,03552	0,13464	0,10192	0,14802
Relação entre comprimento e largura do pavimento tipo	0,00109	0,00392	0,01365	0,00870	0,01529
Número de pavimentos da edificação	0,00009	0,00109	0,01531	0,01016	0,01474
Orientação solar	0,00052	0,00268	0,01427	0,01267	0,01098
Percentual de abertura nas fachadas	0,01500	0,01166	0,07813	0,05478	0,09983
Fator solar dos vidros	0,02478	0,00746	0,12491	0,08535	0,10384
Transmitância térmica dos vidros	0,00034	0,00787	0,05187	0,03760	0,03592
Absortância solar das paredes externas	0,00021	0,00060	0,00399	0,00312	0,00092
Transmitância térmica das paredes externas	0,00001	0,00214	0,00645	0,00579	0,00871
Capacidade térmica das paredes externas	0,00004	0,00008	0,00206	0,00224	0,00300
Absortância solar da cobertura	0,00028	0,00105	0,00478	0,00473	0,00439
Transmitância térmica da cobertura	0,00018	0,00017	0,00399	0,00380	0,00030
Capacidade térmica da cobertura	0,00001	-0,00004	0,00158	0,00221	0,00363
Capacidade térmica das paredes internas	0,00020	0,00020	0,00543	0,00458	0,00035
Infiltração de ar	0,00770	0,02492	0,16849	0,11920	0,12866
Densidade de potência de iluminação	0,00485	0,00414	0,01325	0,01059	0,00858
Índice de ocupação	0,28683	0,06225	0,29785	0,22151	0,39185
Horário de funcionamento	0,15877	0,00970	0,03906	0,02886	0,08304
Clima	0,48075	0,79630	0,56126	0,76967	0,62628
Temperatura do termostato	0,03553	0,02281	0,06261	0,06465	0,16399
Ciclo economizador/recuperador de calor	0,04250	0,39243	0,12877	0,08977	0,11807
Ciclo noturno	-0,00001	-0,00004	0,00005	0,00006	0,00000

(continua)

Tabela 16 – Índices de ordem total relacionando as variáveis e a carga térmica de refrigeração

(conclusão)

ÍNDICES DE ORDEM TOTAL- SOBOL	Carga térmica anual	Histograma de frequência-carga térmica			
		25%	50%	75%	100%
Reset da temperatura da água gelada	-0,00004	0,00088	0,01244	0,01526	0,10820
Tipo de ventilação	0,01137	0,07316	0,16761	0,14053	0,26845
Pressão dos ventiladores	0,01174	0,00508	0,01121	0,00876	0,01244
Tipo de bombeamento da água gelada	-0,00019	0,00109	0,01316	0,01023	0,01522
Pressão das bombas de água gelada	-0,00003	0,00007	-0,00017	0,00010	-0,00029
Pressão das bombas de água de condensação	0,00000	-0,00001	0,00000	0,00000	0,00000
Vazão de ar de renovação	0,00265	0,00104	0,00646	0,00579	0,02110
Chiller	0,00010	0,00184	0,06576	0,04423	0,05153

A Tabela 17 apresenta os valores dos índices de ordem total correspondentes à influência da variação de cada uma das 30 variáveis nos resultados de consumo anual do sistema de climatização.

Tabela 17 – Índices de ordem total relacionando as variáveis e o consumo do sistema de climatização.

ÍNDICES DE ORDEM TOTAL- SOBOL	consumo total	consumo chiller	consumo vent.	consumo bombas	consumo torre
Largura do pavimento tipo	0,02715	0,02554	0,01456	0,00593	0,04181
Relação entre comprimento e largura do pavimento tipo	0,00021	0,00144	-0,00132	-0,00030	0,00025
Número de pavimentos da edificação	-0,00102	-0,00044	-0,00145	0,00093	0,00194
Orientação solar	0,00030	0,00073	-0,00090	0,00008	0,00010
Percentual de abertura nas fachadas	0,00922	0,00809	0,00980	0,00244	0,01259
Fator solar dos vidros	0,02017	0,01624	0,01418	0,00312	0,02154
Transmitância térmica dos vidros	0,00052	0,00049	0,00129	0,00007	0,00088
Absortância solar das paredes externas	-0,00016	-0,00027	0,00000	0,00015	0,00094
Transmitância térmica das paredes externas	0,00003	-0,00003	-0,00023	0,00030	-0,00001

(continua)

Tabela 17 – Índices de ordem total relacionando as variáveis e o consumo do sistema de climatização.

(conclusão)

ÍNDICES DE ORDEM TOTAL- SOBOL	consumo total	consumo chiller	consumo vent.	consumo bombas	consumo torre
Capacidade térmica das paredes externas	0,00000	0,00006	-0,00001	0,00017	-0,00012
Absortância solar da cobertura	0,00044	0,00002	0,00060	0,00034	-0,00056
Transmitância térmica da cobertura	0,00057	0,00033	0,00047	0,00023	0,00033
Capacidade térmica da cobertura	0,00002	0,00001	0,00002	0,00022	-0,00004
Capacidade térmica das paredes internas	0,00050	0,00015	0,00081	-0,00029	0,00077
Infiltração de ar	0,00487	0,00656	0,00193	0,00125	0,00985
Densidade de potência de iluminação	0,00532	0,00370	0,00334	0,00181	0,00214
Índice de ocupação	0,28071	0,22638	0,16840	0,29106	0,06884
Horário de funcionamento	0,10696	0,11301	0,03638	0,03182	0,05443
Clima	0,21016	0,38775	0,00305	0,07520	0,63670
Temperatura do termostato	0,07057	0,02431	0,10806	0,00447	0,02044
Ciclo economizador/recuperador de calor	0,01956	0,03651	0,00011	0,01802	0,02171
Ciclo noturno	0,00047	0,00000	0,00237	0,00000	0,00000
Reset da temperatura da água gelada	0,00053	0,00055	0,00008	0,01194	0,00009
Tipo de ventilação	0,10936	0,00829	0,40223	0,01752	0,01387
Pressão dos ventiladores	0,13145	0,00586	0,40239	0,00156	0,00870
Tipo de bombeamento da água gelada	0,00069	0,00000	0,00000	0,17014	-0,00043
Pressão das bombas de água gelada	0,00024	0,00005	0,00000	0,08752	-0,00018
Pressão das bombas de água de condensação	-0,00188	0,00000	0,00000	0,13297	-0,00084
Vazão de ar de renovação	0,00203	0,00351	0,00007	-0,00091	-0,00049
Chiller	0,12158	0,27399	0,00002	0,27259	0,36959

A análise dos valores apresentados na Tabela 17 permite concluir que dentre as 13 variáveis que até então (fase da análise de sensibilidade sobre os resultados de carga térmica integrada anual e histograma da carga térmica) apresentavam baixa influência, quatro delas mostraram-

se influentes nos consumos do sistema de climatização, a saber: tipo de bombeamento, pressão das bombas de água gelada, pressão das bombas de água de condensação e *chiller*.

Portanto, a principal conclusão da análise de sensibilidade, analisando o objetivo a que foi proposta nesta pesquisa, foi que 9 das 30 variáveis apresentam menor influência sobre os resultados de carga térmica de resfriamento e de consumo do sistema de climatização. E assim, tais variáveis não necessitam ter seus valores alterados no processo de criação da base de dados, podendo assumir valores fixos. A seguir são listadas estas 9 variáveis:

- absorvância solar das paredes externas;
- transmitância térmica das paredes externas;
- capacidade térmica das paredes externas;
- absorvância da cobertura;
- transmitância térmica da cobertura;
- capacidade térmica da cobertura;
- capacidade térmica das paredes internas;
- ciclo noturno;
- reset de temperatura da água gelada.

4.3. AMOSTRAGEM PELO MÉTODO HIPERCUBO LATINO

O primeiro passo para a criação dos casos a serem simulados foi definir os valores a serem empregados para as variáveis. Com o resultado da etapa anterior, o número de variáveis foi reduzido de 30 para 21 variáveis. Portanto, nove variáveis tiveram seus valores fixados, conforme apresentado na Tabela 18. Para definição destes valores, considerou-se como características bastante comuns de edifícios de escritórios brasileiros o uso de paredes construídas com bloco cerâmico (9,0 x 14,0 x 24 cm) e argamassa (espessura 2,5 cm) em ambos os lados, telhado construído com laje pré-moldada com cerâmica (12,0 cm) e telha de fibrocimento, bem como, ausência de ciclo noturno e de reset da temperatura da água gelada. Os valores numéricos das características térmicas referentes a estas arranjos construtivos foram consultados no manual do Selo Caixa Azul (CAIXA ECONÔMICA FEDERAL, 2010).

Tabela 18 – Valores empregados para nove variáveis características.

Variável	Valor utilizado
Absortância solar das paredes externas	0,4
Transmitância térmica das paredes externas	2,6 W/m ² .K
Capacidade térmica das paredes externas	145 kJ/m ² .K
Absortância solar da cobertura	0,5
Transmitância térmica da cobertura	1,93 W/m ² .K.
Capacidade térmica da cobertura	106 kJ/m ² .K
Capacidade térmica das paredes internas	145 kJ/m ² .K
Ciclo Noturno	Ausente
Reset da temperatura da água gelada	Ausente

Uma nova variável foi adicionada ao conjunto de 21 variáveis, totalizando assim 22 variáveis abordadas no processo de criação dos casos para a base de dados. Para avaliar o desempenho do emprego de *chillers* operando em paralelo, houve a inclusão da variável intitulada “número de *chillers* em paralelo”. A motivação para a inclusão desta nova variável deve-se ao fato de que o consumo da central de água gelada difere se a central for composta por *chillers* instalados em paralelo ao invés de um único chiller, conforme abordado por Geister e Thompson (2009). A Tabela 19 apresenta os valores que foram empregados para estas 22 variáveis.

A quantidade de casos determinada pelas possíveis combinações dos valores apresentados acima totaliza 526.727.577.600.000 casos. O tamanho da amostra foi calculado pela Equação 18. O consumo total do sistema de climatização é a variável em estudo no desenvolvimento do metamodelo deste trabalho. O valor do desvio-padrão desta variável obtido, quando os 126.976 casos foram simulados na etapa de análise de sensibilidade, foi de 29,64 kWh/m². Adotando um grau de confiança de 99% e uma margem de erro de 0,5% do valor do desvio padrão (0,15 kWh/m²) obteve-se o tamanho da amostra em 265.225 casos.

Tabela 19 – Valores empregados para as 22 variáveis no processo de geração dos casos.

Variável	Valores utilizados
Largura do pavimento tipo	10, 15, 30 e 50 m
Relação entre o comprimento e a largura do pavimento tipo	1,0; 2,5; 4,0 e 5,5
Número de pavimentos da edificação	5, 10, 30 e 50
Orientação solar da edificação	0, 45, 90 e 135°
Percentual de abertura nas fachadas	0,15; 0,35; 0,55; 0,75 e 0,95
Fator solar dos vidros	0,20; 0,35; 0,50; 0,65 e 0,80
Transmitância térmica do vidro	1,7; 2,7 e 5,8 W/m ² .K
Infiltração de ar	0; 0,25; 0,50 e 0,75 trocas de ar por hora
Densidade de potência de iluminação	7,5; 10,0; 12,5 e 15,0 W/m ²
Índice de ocupação	3, 7, 11 e 15 m ² /pessoa
Horário de funcionamento	8, 10, 12, 14 e 16 horas diárias
Clima	18 arquivos climáticos (Tabela 4)
Temperatura do termostato	20, 22 e 24°C
Ciclo economizador/recuperador de calor	presente/ausente, ou ausente/presente, ou ausente/ausente
Tipo de ventilação	Volume de ar constante (VAC) ou Volume de ar variável (VAV)
Pressão dos ventiladores	150, 250, 350, 450, 550, 650 e 750 Pa
Tipo de bombeamento da água gelada	Primário constante/Secundário variável, ou Somente primário constante, ou Somente primário variável
Pressão das bombas de água gelada	250, 350, 450, 550, 650, 750 e 850 kPa
Pressão das bombas de água de condensação	100, 200, 300, 400, 500 e 600 kPa
Vazão de ar de renovação	Nível 1 / Nível 2 / Nível 3 da NBR 16.401
Chiller	25 chillers diferentes (Anexo A)
Número de chillers em paralelo	1, 2, 3 e 4

Outra forma utilizada para avaliar o tamanho satisfatório da amostra foi calcular o desvio padrão nos valores gerados para cada variável nas amostras obtidas pelo método de Hipercubo Latino. Foram geradas amostras que variaram de 32.000 a 900.000 casos. A Figura 14 apresenta os valores do desvio padrão obtidos, para diversos tamanhos de amostra, para a variável intitulada “índice de ocupação”, cujos valores poderiam ser 3, 7, 11 ou 15 m²/pessoa. Observa-se que o desvio padrão reduz com o aumento do tamanho da amostra de uma forma exponencial, tendendo a um valor fixo. O mesmo comportamento foi observado para as demais variáveis. A taxa de redução torna-se menor quando o tamanho da amostra aumenta de 200.000 para 300.000 casos, o que permite definir que uma amostra desta ordem de grandeza já é suficiente para representar a população de mais de 526 trilhões de casos. Diante destes resultados, e do resultado obtido pela Equação 18, foi definido o tamanho da amostra em 250.000 casos a serem simulados para a criação da base de dados.

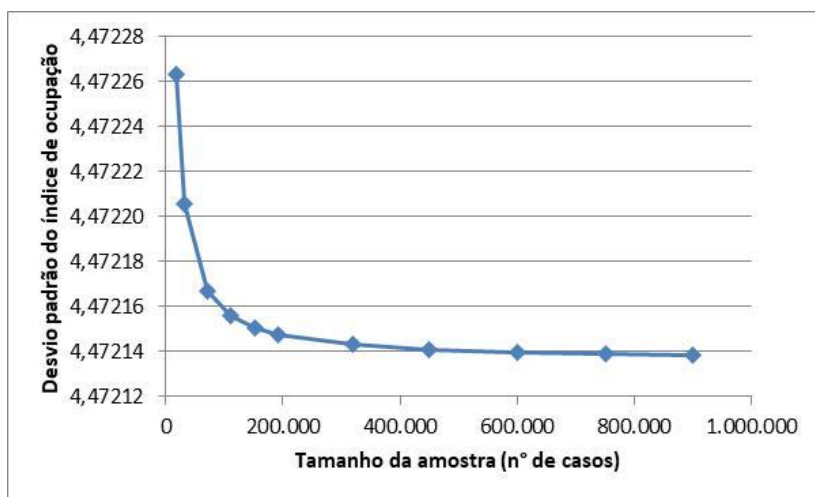


Figura 14 – Desvio padrão dos valores da variável “índice de ocupação” para diferentes tamanhos de amostra.

Antes da criação dos arquivos que compuseram os 250.000 casos (arquivos idf e epw - entrada do programa EnergyPlus), amostras menores de 20 a 800 casos foram gerados e simulados com o objetivo de verificar a confiabilidade do processo de simulação dos casos. Na Etapa 2 (análise de sensibilidade) o *script* elaborado para a criação dos casos foi validado, uma vez que uma minuciosa verificação dos arquivos

gerados permitiu constatar que os mesmos estavam sendo gerados corretamente. Na presente etapa, o foco foi verificar a ocorrência de erros durante o processo simulação que poderiam comprometer os resultados. O processo consistiu em identificar a quantidade de erros e *warnings* listados em cada uma das simulações, e buscar reduzi-los ao máximo. Uma grande quantidade de *warnings* estava presente em simulações que empregavam o sistema VAV, principalmente aqueles que utilizavam recuperador de calor. A situação foi resolvida com o aumento do valor da vazão mínima dos ventiladores, que ficou redefinido em 20% da vazão máxima quando o sistema for VAV sem recuperador de calor, e 65% quando o sistema for VAV com recuperador de calor. O ajuste deste parâmetro e a alteração de outros poucos pontos permitiram reduzir a quantidade de *warnings* para poucas dezenas. Estes avisos remanescentes foram identificados e tem relação com aspectos que não comprometem a confiabilidade dos resultados das simulações.

Uma vez realizada esta etapa de validação do processo de criação e simulação, a amostra com os 250.000 casos foi gerada pelo método de Hipercubo Latino.

4.4. SIMULAÇÕES

A simulação dos 250.000 casos foram realizadas com o uso do supercomputador SDumont, demandando um tempo de processamento em torno de 40 horas, sendo que o tempo de espera em fila de simulação ficou em torno de uma semana. Ao final do processo de simulação, a combinação do arquivo que definiu os casos a serem simulados com os arquivos de resultados e de erros, compuseram a base de dados que foi empregada para o desenvolvimento de metamodelos.

4.5. PRÉ-PROCESSAMENTO DOS DADOS

Após a obtenção dos dados gerados pelas simulações, os resultados foram analisados para avaliar se o dimensionamento do sistema de climatização, realizado pelo programa EnergyPlus, foi eficaz. Conforme descrito no método, foram considerados subdimensionados, os casos em que o percentual de horas não atendidas foi superior à 10%. Nos resultados, observou-se que apenas 2,2% dos casos simulados apresentaram subdimensionamento. Frente a isso, optou-se em se retirar estes 5.405 casos da base de dados.

Outro procedimento adotado foi verificar a ocorrência de erros severos nas simulações. Dentre os casos restantes na base de dados (244.595 casos), 632 casos apresentaram erros severos e por esta razão

foram retirados da base de dados. Assim, a base de dados que foi empregada para o desenvolvimento dos metamodelos ficou composta por 243.963 casos.

Buscando demonstrar que o uso do COP do chiller, ou do seu IPLV, para estimar o consumo do sistema de climatização, a partir do conhecimento da carga térmica, não é um método adequado, a Figura 15 apresenta a relação entre a razão carga térmica/COP e o consumo do sistema de climatização para os casos da base de dados, enquanto a Figura 16 apresenta a relação entre a razão carga térmica/IPLV e o consumo.

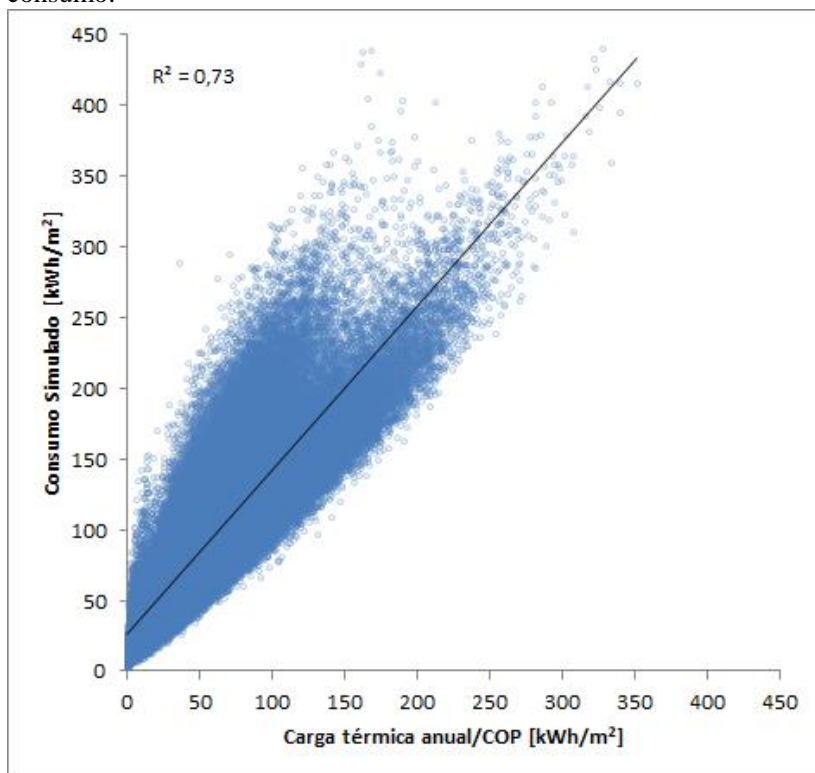


Figura 15 – Relação entre a razão carga térmica anual/COP e consumo.

A regressão linear resultou em $R^2 = 0,73$ e erro padrão = 25,18 kWh/m², quando o COP é utilizado para estimar o consumo a partir da carga térmica, e $R^2 = 0,7998$ e erro padrão = 21,69 kWh/m², quando o IPLV é utilizado para estimar o consumo a partir da carga térmica. Tais

resultados evidenciam que análises de eficiência energética de sistemas de climatização, que utilizam somente o COP ou o IPLV do chiller, não são eficazes.

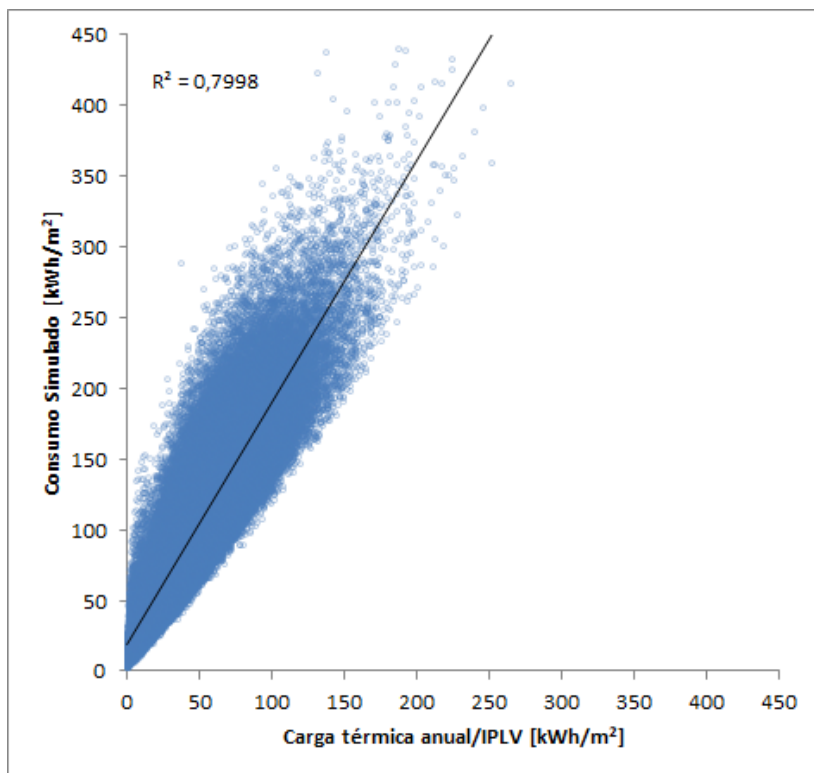


Figura 16 – Relação entre a razão carga térmica anual/IPLV e consumo.

Dando continuidade ao processo de pré-processamento, algumas variáveis da base de dados, utilizadas no processo de simulação, foram substituídas. Trata-se de parâmetros de categoria (que não possuem representação numérica) e que foram decompostos em variáveis mais específicas. A variável intitulada “ciclo economizador/recuperador de calor”, parametrizada com três categorias, foi substituída por duas variáveis (ciclo economizador e recuperador de calor), ambas binárias (0-ausente, 1-presente). Da mesma forma, a variável “tipo de bombeamento de água gelada” foi substituída por duas variáveis (uso de circuito secundário e uso de vazão variável), ambas binárias (0-ausente,

1-presente). Tais transformações se encontram também descritas na Tabela 20.

Tabela 20 – Substituição das variáveis ciclo economizador/recuperador de calor e tipo de bombeamento de água gelada.

Variável original		Novas variáveis			
nome	valores	nome	valor	nome	valor
Ciclo economizador / recuperador de calor	presente/ausente	Ciclo economizador	1	Recuperador de calor	0
	ausente/presente		0		1
	ausente/ausente		0		0
Tipo de bombeamento de água gelada	Primário constante / secundário variável	Uso de circuito secundário	1	Uso de vazão variável	1
	Somente primário constante		0		0
	Somente primário variável		0		1

A variável “nível de renovação” teve suas três categorias (Nível 1, Nível 2 e Nível 3) substituídas pelos valores numéricos 2,5; 3,1 e 3,8; correspondentes aos valores da vazão de ar (l/s) por pessoa definidos na norma NBR 16.401 para cada um dos três níveis de renovação.

A variável *chiller*, parametrizada entre os valores de 0 a 24, foi substituída pelas variáveis COP a 100% e IPLV com os respectivos valores de cada *chiller* (Anexo A). O histograma de frequência da carga térmica de refrigeração, que foi gerada pela simulação em 20 classes (bins), foi agrupada para compor somente quatro classes (0-25%, 25-50%, 50-75% e 75-100%).

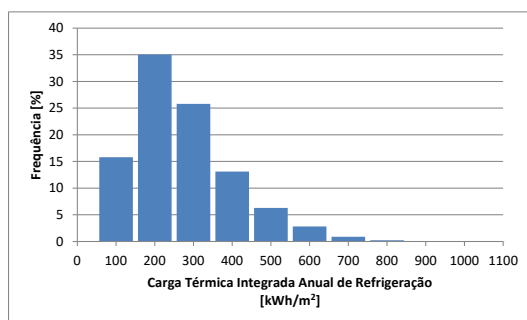
A arquitetura inicial do modelo de rede neural considerou o emprego de 18 variáveis predictoras (nós de entrada) e 1 variável de resposta (nó de saída), conforme listadas na Tabela 21.

Tabela 21 – Variáveis preditoras e variável de resposta - arquitetura inicial da RNA.

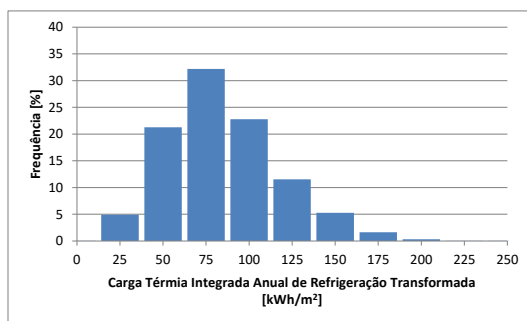
Variável	Descrição
Preditora 1	Tipo de ventilação (VAC ou VAV)
Preditora 2	Pressão dos ventiladores (Pa)
Preditora 3	Uso de ciclo economizador (0-ausente, 1-presente)
Preditora 4	Uso de recuperador de calor (0-ausente, 1-presente)
Preditora 5	Nível de renovação de ar
Preditora 6	Pressão do bombeamento de água gelada (Pa)
Preditora 7	Pressão do bombeamento de água de condensação (Pa)
Preditora 8	Uso de circuito secundário de água gelada (0-ausente, 1-presente)
Preditora 9	Uso de vazão variável de água gelada (0-ausente, 1-presente)
Preditora 10	COP a 100% de carga do <i>chiller</i> nas condições AHRI 550/590
Preditora 11	IPLV do <i>chiller</i> nas condições AHRI 550/590
Preditora 12	Número de <i>chillers</i> operando em paralelo
Preditora 13	Carga térmica integrada anual de resfriamento por área de piso (kWh/m ²)
Preditora 14	Indicador climático (CEH)
Preditora 15	Classe 1 do histograma da carga térmica (% de frequência entre 0-25%)
Preditora 16	Classe 2 do histograma da carga térmica (% de frequência entre 25-50%)
Preditora 17	Classe 3 do histograma da carga térmica (% de frequência entre 50-75%)
Preditora 18	Classe 4 do histograma da carga térmica (% de frequência entre 75-100%)
Variável de resposta	Consumo total do sistema de climatização por área de piso (kWh/m ²)

Outras transformações empregadas foram a centralização, o escalonamento e a correção de assimetria dos dados. Todas as variáveis passaram pela transformação de centralização e escalonamento dos dados através das funções *center* e *scale* presentes no pacote *caret* da linguagem R (KUHN, 2008). Com relação à simetria, as variáveis oriundas do processo de amostragem por Hipercubo Latino (variáveis utilizadas como dados de entrada das simulações) já apresentam distribuição simétrica devido ao processo de amostragem. As variáveis

carga térmica integrada anual de refrigeração e consumo do sistema de climatização, que foram resultados das simulações, foram analisadas quanto a sua distribuição e passaram por uma transformação para reduzir a assimetria dos dados. O método de transformação utilizado foi o Box-Cox (Equação 20), que consiste em uma transformação indexada por um parâmetro λ . O valor de λ foi obtido para cada variável através da função *boxcox* presente no pacote *mass* da linguagem R (VENABLES e RIPLEY, 2002), sendo $\lambda=0,74747$ para a carga térmica integrada anual de refrigeração e $\lambda=0,70707$ para o consumo total do sistema de climatização. A Figura 17 apresenta a distribuição da variável carga térmica integrada anual de refrigeração antes e depois da transformação, enquanto a Figura 18 apresenta a distribuição da variável consumo do sistema de climatização. Tais transformações têm como objetivo melhorar o processo de obtenção do metamodelo, no presente caso, o treinamento de redes neurais artificiais.

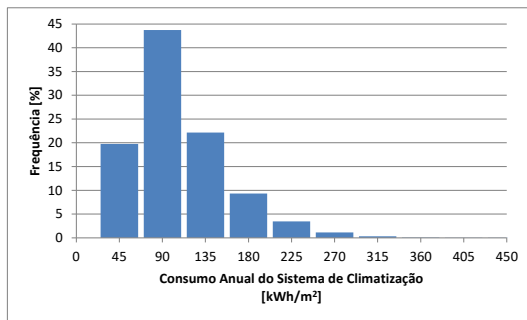


(a)

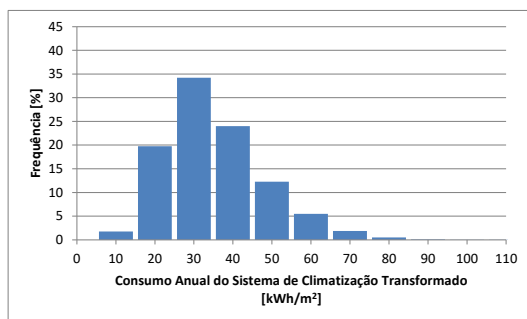


(b)

Figura 17 – Distribuição de frequência da carga térmica anual de refrigeração: (a) antes da transformação e (b) depois da transformação.



(a)



(b)

Figura 18 – Distribuição de frequência do consumo do sistema de climatização: (a) antes da transformação e (b) depois da transformação.

4.6. TREINAMENTO DE MODELOS COM DIFERENTES TAMANHOS DE AMOSTRA

Como resultado da etapa anterior, obteve-se uma base de dados composta por 243.963 casos, caracterizada por 18 variáveis preditoras e 1 variável de saída. O uso da base de dados completa para o treinamento de redes neurais é inviável devido ao tempo de processamento, portanto foi necessário definir um tamanho de amostra que garantisse uma confiança satisfatória. A Equação 5 foi empregada considerando cinco graus de confiança distintos, 90%, 95%, 99,0%, 99,5% e 99,9%, que corresponde a utilizar os valores de $Z_{\alpha/2}$ iguais à 1,645, 1,960, 2,575, 3,090 e 3,291, respectivamente. O tamanho da população é o número total de casos (243.963), a variável consumo do sistema de climatização apresentou desvio padrão igual a 48,47 kWh/m², e o erro máximo da estimativa foi considerado igual a 1% do desvio padrão (0,48 kWh/m²). Desta forma, os resultados obtidos para os tamanhos de amostra para os

cinco graus de confiança foram: 24.359, 33.190, 52.136, 68.624 e 75.008 casos, que correspondem à 10%, 14%, 21%, 28% e 31% dos casos, respectivamente. Diante destes resultados, optou-se por testar o emprego de amostras com tamanhos de 5%, 10%, 15%, 20%, 25% e 30% dos casos. Nota-se que além de valores próximos aos obtidos com a Equação 5, um tamanho adicional foi incluído (5%) com o objetivo de analisar os resultados também para este caso.

Para cada tamanho de amostra, uma rede neural com apenas uma camada interna contendo 13 neurônios foi treinada, empregando validação cruzada repetida 6 vezes com k-fold igual a 10. Utilizando cada uma das redes para prever o consumo de energia do sistema de climatização de toda a população (243.963 casos) obteve-se os índices de desempenho (R^2 , RMSE e NRMSE). Os valores destes índices, bem como o tempo de processamento para treinar cada rede, são apresentados na Tabela 22.

Tabela 22 – Índices de desempenho das RNAs para diferentes tamanhos de amostra.

Tamanho da amostra	R^2	RMSE	NRMSE	Tempo de processamento [s]
5%	0,9823	6,451413	0,075971	619
10%	0,9827	6,374540	0,075066	1.353
15%	0,9832	6,277394	0,073922	1.785
20%	0,9832	6,284369	0,074004	2.742
25%	0,9834	6,251366	0,073615	3.206
30%	0,9837	6,196346	0,072967	3.647

Os resultados demonstram que o tempo de processamento tem relação linear com o tamanho da amostra. Os demais índices (R^2 , RMSE e NRMSE) apresentaram melhoria nos valores à medida que o tamanho da amostra é aumentado, sendo esta melhoria maior nos primeiros acréscimos (amostra com 10 e 15%) e menores nos subsequentes (20, 25 e 30%). O RMSE, por exemplo, apresentou uma redução de 1,2% quando a amostra passou de 5 para 10%, 1,5% quando passou de 10 para 15%, um leve acréscimo de 0,1% quando passou de 15 para 20%, uma redução de 0,5% quando passou de 20 para 25% e de 0,9% quando passou de 25 para 30%. Diante deste comportamento, optou-se pelo emprego da amostra de 15% nas etapas seguintes, pois as pequenas melhorias obtidas com tamanhos de amostra superiores (20%, 25% e

30%) não justificam o acréscimo do tempo de processamento, o qual tem comportamento linear com o tamanho da amostra.

4.7. APRIMORAMENTO DO METAMODELO

O primeiro aprimoramento do metamodelo foi realizado através da variação do tamanho da camada interna (número de nós) da rede neural. Foram desenvolvidos metamodelos com número de nós na camada interna nas proporções de 0,35; 0,5; 0,8; 0,95; 1,1; 1,25; 1,4; 1,55; 1,7; 1,85 e 2,0 vezes o valor de N (soma da quantidade de variáveis independentes e dependentes). Como o modelo apresenta 18 variáveis preditoras e 1 variável de saída, o valor de N é igual a 19, e assim foram modeladas RNAs com 7, 10, 15, 18, 21, 24, 27, 29, 32, 35 e 38 neurônios na camada interna. Os mesmos índices de desempenho empregados na etapa anterior (R^2 , RMSE, NRMSE e tempo de processamento) foram obtidos. Outro índice calculado foi o índice síntese de desempenho global (IDG), conforme utilizado por Versage (2015) e elaborado com base no índice de síntese (SI) de Chou e Bui (2014). Tal índice define qual rede neural apresenta o melhor custo-benefício, uma vez que é calculado com os valores de R^2 , RMSE e tempo de processamento, conforme Equação 21. A Tabela 23 apresenta os valores obtidos para estes índices para cada rede neural treinada com diferentes tamanhos de camada interna.

Tabela 23 – Índices de desempenho das RNA com diferentes tamanhos de camada interna.

Neurônios na camada interna	R^2	RMSE	NRMSE	Tempo de processamento [s]	IDG
7	0,9805	6,770785	0,079732	983	0,33
10	0,9820	6,509469	0,076654	1.331	0,44
13	0,9832	6,277394	0,073922	1.785	0,53
15	0,9840	6,141224	0,072318	2.297	0,58
18	0,9846	6,019004	0,070879	3.162	0,60
21	0,9851	5,918551	0,069696	4.252	0,61
24	0,9859	5,752918	0,067745	5.664	0,63
27	0,9869	5,558890	0,065461	6.538	0,69
29	0,9864	5,643663	0,066459	7.736	0,61
32	0,9881	5,294593	0,062348	8.825	0,72
35	0,9869	5,550854	0,065366	9.240	0,60
38	0,9883	5,247043	0,061788	10.989	0,67

$$IDG = \frac{R^2 - R_{mín}^2}{R_{máx}^2 - R_{mín}^2} + \frac{RMSE - RMSE_{mín}}{RMSE_{máx} - RMSE_{mín}} + \left(1 - \frac{tempo - tempo_{mín}}{tempo_{máx} - tempo_{mín}}\right) \quad (21)$$

A rede neural que apresentou melhor relação desempenho/tempo de processamento (maior valor de IDG) foi a rede com 32 neurônios na camada interna (relação 1,7 x N), que foi designada como rede neural base (RNA 32). A Figura 19 apresenta os resultados obtidos ao empregar esta rede para prever o consumo do sistema de climatização para toda a população. Tal gráfico ilustra que há uma boa concordância entre os valores simulados e os valores preditos ($R^2=0,9881$). Sendo assim, esta arquitetura de rede (32 neurônios na camada interna) foi utilizada nos estudos que se seguiram.




Figura 19 – Consumo predito versus consumo simulado (RNA 32 = 18 neurônios de entrada, 32 na camada interna e 1 neurônio de saída).

Ao avaliar os erros que ocorrem ao estimar o consumo do sistema de climatização com o uso da rede neural base (RNA 32), verificou-se que os maiores erros percentuais ocorrem para os casos simulados com os dois menores valores empregados do indicador CEH (12.217 referente à Petrópolis-RJ, e 34.190 referente à Campos do Jordão-SP), conforme pode ser visualizado na Figura 20.

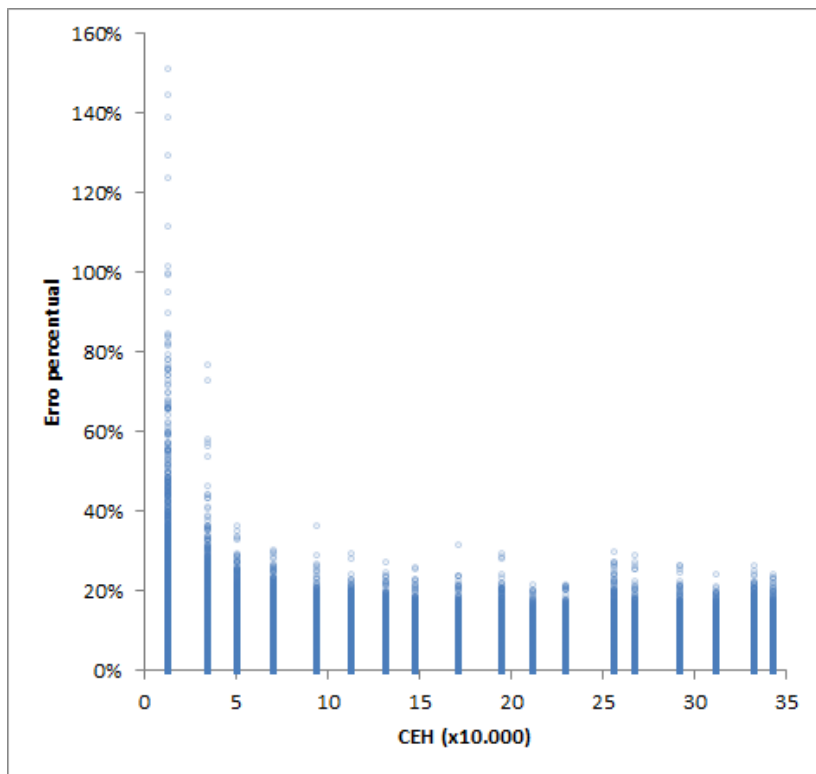


Figura 20 – Erro percentual da predição de consumo do sistema de climatização com o uso da RNA 32 para os casos da base de dados, agrupados pelo CEH.

Nesta avaliação foi verificado que 195 casos (0,08% do total de 243.963 casos da base de dados) apresentaram erros percentuais na predição superior a 37% (valor máximo obtido para os casos com CEH igual ou superior a 50.577). A justificativa para que nos climas mais frios a rede neural apresente maiores erros é que a carga térmica das edificações nestes climas é menor e o sistema de climatização opera em baixa carga parcial durante uma parte significativa do tempo. Na modelagem dos

chillers há uma variável chamada *minimum unloading* que define qual o menor percentual de capacidade em que o equipamento pode modular, abaixo deste valor o equipamento utiliza estratégias de carregamento, tais como *by-pass* de gás quente, que permite atender a carga térmica reduzida mas sem reduzir o consumo de energia. Como os *chillers* utilizados nas simulações apresentam uma gama variada de valores para o *minimum unloading* (valores entre 9 e 39%), o consumo anual de energia pode ser bastante distinto para cada *chiller* quando há a predominância da operação em baixa carga parcial, resultante de baixa carga térmica (climas frios). A rede neural artificial não consegue captar tais variações durante o treinamento, visto que a variável *minimum unloading* não se encontra entre as variáveis de entrada da rede neural, gerando assim maiores erros de predição nesta faixa de climas frios. Diante desta constatação, entende-se que o uso da rede deve ser restrita a valores de CEH superiores a 50.000, nos quais os erros de predição apresentam a mesma ordem de grandeza. Com esta restrição, o desempenho da rede neural artificial base (RNA 32) é tal que em 65,8% dos casos o erro percentual da predição é inferior a 5%, e em 98,9% dos casos o erro percentual é inferior a 15%, demonstrando assim que este metamodelo apresenta um bom desempenho.

Após o estudo da variação do número de neurônios na camada interna, foi avaliada a influência do uso da carga térmica, e de seu histograma, como variáveis preditoras na rede neural do metamodelo. Uma nova rede neural foi treinada empregando 12 variáveis preditoras adicionais, ao invés do emprego da carga térmica e de seu histograma, resultando assim em uma arquitetura de rede composta por 25 variáveis preditoras e 1 variável de saída. Esta nova rede neural também foi treinada através de validação cruzada com 10 k-fold repetida 6 vezes, sendo que a rede com 40 neurônios na camada interna apresentou maior valor de IDG. A Tabela 24 apresenta os dados de desempenho (R^2 , RMSE e NRMSE) da rede neural base e da nova rede neural (RNA 40_geral).

Tabela 24 – Índices de desempenho da rede neural base e da rede neural RNA 40_geral.

Rede Neural	Neurônios na camada interna	R^2	RMSE	NRMSE
RNA 32	32	0,9881	5,294593	0,062348
RNA 40_geral	40	0,9909	4,628447	0,054504

A rede neural artificial RNA 40_geral, quando avaliada para os casos com CEH maior do que 50.000, apresentou em 69,9% dos casos o erro percentual na predição inferior a 5%, e em 98,6% dos casos o erro percentual inferior a 15%. Os resultados demonstram que o desempenho das duas redes são similares, sendo que a rede com maior número de variáveis preditoras (RNA 40_geral) tem, como esperado, um desempenho superior à rede base (RNA 32). Portanto, a adoção da carga térmica da edificação, e de seu histograma, como variáveis preditoras mostrou-se adequada para representar a edificação no metamodelo, sem resultar em perda de desempenho no processo de predição do consumo do sistema de climatização.

Para avaliar quais os ganhos que podem ser obtidos se forem desenvolvidos dois metamodelos, um para chiller a ar e outro para chiller a água, duas novas redes neurais artificiais foram treinadas. A base de dados possui 68.362 casos com *chiller* a ar, e 175.601 casos com *chiller* a água. O tamanho de amostra utilizada no treinamento foi recalculada empregando a Equação 5, e utilizando grau de confiança de 95% e erro de 1% do desvio padrão da variável consumo, obteve-se o tamanho de amostra de 36% dos casos para o treinamento da rede para *chiller* a ar, e 18% dos casos para o treinamento da rede para *chiller* a água. A Tabela 25 apresenta os resultados de desempenho para estas novas redes neurais, bem como para a rede neural base. Houve uma melhoria (redução de 20% no NRMSE) quando uma rede neural foi treinada para predição de casos que empregam *chiller* a ar (RNA 32_ar), quando comparada com a rede neural base (RNA 32) que foi desenvolvida para predição de ambos os casos (*chiller* a ar e a água). A rede neural treinada para a predição de casos que empregam *chiller* a água (RNA 32_água) apresentou menor desempenho que a rede neural base (RNA 32), com um aumento de 5,4% no valor do NRMSE. Analisando as características dos *chillers* utilizados (curvas de desempenho e parâmetros, tais como *minimum unloading* – ANEXO A), identifica-se que os *chillers* a ar são mais uniformes, enquanto que os *chillers* a água apresentam características mais distintas entre si. Tal fato justifica os desempenhos apresentados pelas novas redes, RNA 32_ar e RNA 32_agua, visto que para *chiller* a ar as características são mais homogêneas, facilitando a rede neural a captar os padrões existentes entre as variáveis preditoras e a variável de saída. Neste trabalho optou-se em manter uma única rede neural para a predição de ambos os casos.

Tabela 25 – Índices de desempenho da rede neural base e das redes neurais treinadas separadamente para os casos com *chiller* a ar (RNA 32_ar) e a água (RNA 32_água).

Rede Neural	Neurônios na camada interna	R²	RMSE	NRMSE
RNA 32	32	0,9881	5,294593	0,062348
RNA 32_ar	32	0,9922	4,698166	0,049886
RNA 32_água	32	0,9865	5,345434	0,065737

Uma alteração analisada na arquitetura da rede neural do metamodelo foi a substituição do valor do IPLV do chiller, pelos valores de COP a 25%, COP a 50% e COP a 75% de carga parcial, que compõe a equação de cálculo do IPLV (Equação 19), como variáveis preditoras. Uma nova rede neural foi treinada (com validação cruzada 10 k-fold repetida 6 vezes) com 32, 35 e 38 neurônios na camada interna. Os melhores resultados foram obtidos com o emprego de 35 neurônios na camada interna. A Tabela 26 apresenta os índices de desempenho desta rede neural (RNA 35_COP), bem como o da rede base.

Tabela 26 – Índices de desempenho da rede neural base e da rede neural com substituição da variável preditora IPLV.

Rede Neural	Neurônios na camada interna	R²	RMSE	NRMSE
RNA 32	32	0,9881	5,294593	0,062348
RNA 35_COP	35	0,9887	5,158972	0,060751

Os resultados de desempenho obtidos com a substituição da variável preditora IPLV demonstram uma melhoria de desempenho (redução de 2,6% no RMSE, em relação a rede neural base – RNA 32). Desta forma, tal alteração será reavaliada na etapa seguinte (avaliação em casos não vistos).

A última alteração realizada teve como objetivo avaliar a influência do emprego dos valores do histograma da carga térmica de resfriamento como variáveis preditoras. A rede neural base utiliza quatro valores (classes) do histograma da carga térmica, enquanto uma nova rede neural foi treinada sem o emprego destes valores como variáveis preditoras. A rede neural foi treinada através de validação cruzada 10 k-fold repetida 6 vezes, com 24, 27, 29 e 32 neurônios na camada interna. Os melhores resultados foram obtidos com o emprego de 29 neurônios

na camada interna. A Tabela 27 apresenta os dados de desempenho para esta nova rede neural (RNA 29_sHIS) e para a rede base.

Tabela 27 – Índices de desempenho da rede neural base e da rede neural sem o emprego do histograma da carga térmica como variável preditora.

Rede Neural	Neurônios na camada interna	R²	RMSE	NRMSE
RNA 32	32	0,9881	5,294593	0,062348
RNA 29_sHIS	29	0,9858	5,771209	0,067961

Os resultados de desempenho obtidos com a retirada de quatro variáveis preditoras (histograma de carga térmica de resfriamento) mostram que houve redução de desempenho (aumento de 9,0% no RMSE). No entanto, tal alteração não foi descartada e será reavaliada na etapa seguinte (avaliação em casos não vistos), porque o ganho na redução da complexidade da rede talvez justifique a redução de desempenho.

Diante dos resultados, três redes neurais obtidas nesta etapa foram selecionadas para terem seu desempenho reavaliado na próxima etapa desta pesquisa, a saber: rede base RNA 32 (18 variáveis preditoras e 32 neurônios na camada interna), rede RNA 35_COP (20 variáveis preditoras e 35 neurônios na camada interna), e rede RNA 29_sHIS (14 variáveis preditoras e 29 neurônios na camada interna). A Figura 21 apresenta o diagrama de caixa (*boxplot*) construído com os erros percentuais obtidos no processo de predição dos casos da base de dados que apresentam valores de CEH>50.000. As três redes neurais apresentam resultados similares quando o erro percentual no processo de predição é avaliado (mediana em torno de 3,6%, primeiro quartil em torno de 1,7% e segundo quartil em torno de 6,3%).




Figura 21 – Diagrama de caixa (*boxplot*) para o erro percentual da predição de consumo com o uso de três redes neurais para os casos da base de dados com CEH superiores a 50.000.

A próxima etapa consistirá na geração de novos casos utilizando valores para as variáveis diferentes daqueles empregados anteriormente (Etapa 4), e no emprego destas três redes neurais para prever o consumo anual de energia do sistema de climatização destes novos casos.

4.8. AVALIAÇÃO DO METAMODELO

4.8.1. Avaliação do metamodelo para casos não vistos

O procedimento empregado para a obtenção da base de dados (Etapas 3 à 5) foi novamente realizado para a criação dos chamados casos não vistos. Os valores empregados para as 22 variáveis são apresentados na Tabela 28. Para 17 destas variáveis, foram empregados valores distintos daqueles utilizados quando da criação da base de

dados. As outras 5 variáveis mantiveram seus valores por se tratarem de variáveis categóricas.

Tabela 28 – Valores empregados para as variáveis na criação dos casos não vistos.

Variável	Valores utilizados
Largura do pavimento tipo	20 e 40 m
Relação entre o comprimento e a largura do pavimento tipo	1,75 e 4,75
Número de pavimentos da edificação	40
Orientação solar da edificação	22,5 e 112,5°
Percentual de abertura nas fachadas	0,25 e 0,65
Fator solar dos vidros	0,27 e 0,57
Transmitância térmica do vidro	4,3 W/m ² .K
Infiltração de ar	0,37 trocas de ar por hora
Densidade de potência de iluminação	8,75 e 13,75 W/m ²
Índice de ocupação	5 e 13 m ² /pessoa
Horário de funcionamento	9 e 13 horas diárias
Clima	6 arquivos climáticos (Tabela 29)
Temperatura do termostato	23°C
Ciclo economizador/recuperador de calor	presente/ausente, ou ausente/presente, ou ausente/ausente
Tipo de ventilação	VAC ou VAV
Pressão dos ventiladores	200 e 600 Pa
Tipo de bombeamento da água gelada	Primário constante/Secundário variável, ou Somente primário constante, ou Somente primário variável
Pressão das bombas de água gelada	300 e 600 kPa
Pressão das bombas de água de condensação	150 e 450 kPa
Vazão de ar de renovação	Nível 2 da NBR 16.401
Chiller	7 chillers diferentes (Anexo B)
Número de chillers em paralelo	1, 2, 3 e 4

Tabela 29 – Arquivos climáticos utilizados para a criação dos casos não vistos.

Cidade	CEH
Curitiba-PR	61.135
Uruguaiana-RS	105.618
Campinas-SP	161.406
Petrolina-PE	220.418
Teresina-PI	281.574
Humaitá-AM	319.112

A quantidade de casos determinada pelas possíveis combinações dos valores apresentados acima totaliza 6.193.152 casos. Como se deseja uma amostra inferior a 5% desta população, podemos considerar que a população é infinita e assim calcular o tamanho da amostra para uma estimativa confiável da média populacional pela Equação 18. O valor do desvio-padrão do consumo total do sistema de climatização (variável de interesse no presente estudo), obtido quando os 250.000 casos foram simulados, foi de 48,47 kWh/m². Adotando este valor, um grau de confiança de 99%, e uma margem de erro de 1,0% do valor do desvio padrão (0,48 kWh/m²), obteve-se o tamanho da amostra de 66.300 casos.

A amostragem dos 66.300 casos foi realizada através do método Hipercubo Latino. A simulação destes casos também empregou o supercomputador Santos Dumont (SDumont). Ao final do processo de simulação, os resultados foram pré-processados da mesma forma descrita no item 4.5. Após o pré-processamento restaram 65.697 casos que compuseram os resultados dos chamados casos não vistos.

Três redes neurais obtidas na etapa anterior (RNA 32, RNA35_COP e RNA29_sHIS) foram utilizadas para prever o consumo anual do sistema de climatização destes novos casos. A Tabela 30 apresenta os dados de desempenho obtidos quando cada uma das redes neurais foi empregada.

Tabela 30 – Índices de desempenho das redes neurais na predição do consumo anual do sistema de climatização nos casos não vistos.

Rede Neural	Neurônios na camada interna	R²	RMSE	NRMSE
RNA 32	32	0,9730	4,471439	0,072966
RNA 35_COP	35	0,9776	4,108731	0,067047
RNA 29_sHIS	29	0,9789	3,908977	0,063788

A Figura 22 apresenta o diagrama de caixa (*boxplot*) construído com os erros percentuais obtidos no processo de previsão dos casos não vistos com o uso das três redes neurais (RNA 32, RNA 35_COP e RNA 29_sHIS). Os resultados são similares, com a rede neural RNA 29_sHIS apresentando os menores valores para a mediana (4,1%), primeiro quartil (1,9%) e terceiro quartil (7,1%), ou seja, a previsão com o uso da RNA 29_sHIS apresentou em 50% dos casos erro percentual entre 1,9% e 7,1%. Outra análise dos erros percentuais permite verificar que em 59,0% dos casos o erro percentual da previsão é inferior a 5%, e em 97,5% dos casos o erro percentual é inferior a 15%.




Figura 22 – Diagrama de caixa (*boxplot*) para o erro percentual da previsão de consumo com o uso de três redes neurais para os casos não vistos.

Todas as redes neurais apresentaram um bom desempenho, uma vez que o valor de R^2 permaneceu acima de 0,97. A diferença entre o maior e o menor valor de NRMSE ficou na ordem de 14%, similar à diferença obtida na etapa anterior (11%). Conforme esperado, os valores de R^2

foram inferiores aqueles obtidos quando do uso da rede para prever a base de dados, visto que tais redes foram treinadas a partir de amostras daquela mesma base de dados. A rede neural mais simplificada (RNA 29_sHIS), a qual não utiliza o histograma de frequência como variável preditora, apresentou o melhor desempenho na predição dos casos não vistos (menor NRMSE e maior R^2). A Figura 23 apresenta os resultados obtidos ao empregar esta rede neste processo de predição.

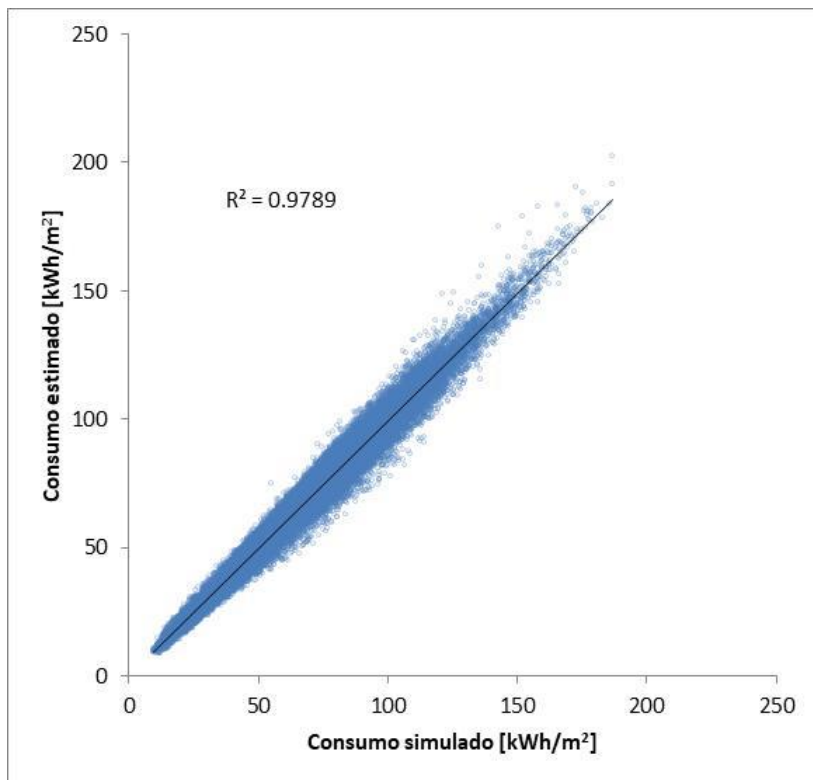


Figura 23 – Consumo predito versus consumo simulado para os casos não vistos (rede RNA29_sHIS - 14 neurônios de entrada, 29 neurônios na camada interna e 1 neurônio de saída).

Diante destes resultados a rede neural RNA 29_sHIS foi escolhida como metamodelo final da presente pesquisa, pois apresenta um bom desempenho utilizando uma arquitetura de rede menos complexa. Assim o metamodelo final é capaz de prever o consumo anual do sistema de climatização de edifícios de escritórios brasileiros por metro quadrado

de área de piso (kWh/m^2), a partir do conhecimento do valor de 14 variáveis (tipo de ventilação, pressão dos ventiladores, uso de ciclo economizador, uso de recuperador de calor, nível de renovação de ar, pressão do bombeamento de água gelada, pressão do bombeamento de água de condensação, uso de circuito secundário de água gelada, uso de vazão variável de água gelada, COP do chiller à 100% de capacidade, IPLV do chiller, número de chillers operando em paralelo, carga térmica integrada anual de resfriamento por metro quadrado de área de piso, e o valor do indicador climático CEH). O erro percentual com o uso desta rede (RNA 29_sHIS) foi inferior a 15% em 98,4% quando o consumo foi predito para os casos da base de dados com $\text{CEH} > 50.000$, e em 97,5% quando o consumo foi predito para os casos não vistos.

4.8.2. Avaliação do metamodelo em climas com distintos perfis de radiação solar

Novos casos foram simulados para duas cidades: Bom Jesus da Lapa-BA e Paraty-RJ. Estas cidades se caracterizam por apresentar valor do indicador climático CEH semelhantes (184.620 para Bom Jesus da Lapa, e 184.506 para Paraty), mas perfis de radiação bastante distintos (Bom Jesus da Lapa apresenta, no arquivo climático utilizado nas simulações, taxa média de radiação solar direta 54% maior do que Paraty). Para a criação destes novos casos, foram adotados os mesmos valores utilizados para a criação da base de dados (Tabela 19), exceto para o percentual de abertura nas fachadas, fator solar dos vidros e transmitância térmica do vidro, para os quais foram utilizados os valores de 0,95, 0,8 e $5,8 \text{ W/m}^2 \cdot \text{K}$, respectivamente. Desta forma, as edificações geradas apresentam grande área envidraçada, com vidros de alto fator solar e transmitância térmica, contribuindo assim para uma maior influência da radiação solar sobre a carga térmica destas edificações.

O tamanho da amostra dos casos a serem simulados foi calculado pela Equação 18, considerando o valor do desvio-padrão do consumo do sistema de climatização igual a $48,47 \text{ kWh/m}^2$ (obtido quando os 250.000 casos foram simulados na Etapa 4), um grau de confiança de 99%, e uma margem de erro de 10% do valor do desvio padrão ($4,8 \text{ kWh/m}^2$). Assim, a amostragem de 650 casos foi realizada através do método Hipercubo Latino. A simulação destes casos também empregou o supercomputador Santos Dumont (SDumont). Ao final do processo de simulação, os resultados foram pré-processados da mesma forma descrita no item 4.5. Após o pré-processamento, restaram 638 casos simulados com o clima de Paraty e 590 casos simulados com o clima de Bom Jesus da Lapa.

Duas redes neurais obtidas na etapa anterior (RNA29_sHIS e RNA40_geral) foram utilizadas para prever o consumo anual do sistema de climatização destes novos casos. A Tabela 31 apresenta os dados de desempenho obtidos quando cada uma das redes neurais foi empregada.

Tabela 31 – Índices de desempenho das redes neurais na predição do consumo anual do sistema de climatização em climas com distintos perfis de radiação solar.

Rede Neural	Cidade	RMSE	NRMSE
RNA 29_sHIS	Paraty	6,4185	0,063308
RNA 29_sHIS	Bom Jesus da Lapa	11,3626	0,090814
RNA 40_geral	Paraty	11,9596	0,117963
RNA 40_geral	Bom Jesus da Lapa	18,1020	0,144679

Os resultados demonstram que o metamodelo definido como metamodelo final (RNA 29_sHIS) apresenta desempenho superior no processo de predição, quando comparado com a rede neural RNA 40_geral. Isso se justifica pelo fato de a radiação ter influência somente na determinação da carga térmica, e que na rede RNA 29_sHIS tal influência já se encontra incorporada ao modelo, pois a carga térmica é uma variável de entrada. Na rede RNA 40_geral, as características da edificação são variáveis de entrada, e desta forma, a carga térmica é estimada pelo metamodelo, resultando assim no menor desempenho desta rede, principalmente quando a radiação solar é mais intensa (Bom Jesus da Lapa). Nota-se também que os valores de RMSE e NRMSE obtidos com a RNA 29_sHIS para a cidade de Paraty são próximos aos valores obtidos quando a rede foi avaliada nos 250.000 casos da base de dados (RMSE=5,294593 e NRMSE=0,062348).

A Figura 24 apresenta o diagrama de caixa (*boxplot*) construído com os erros percentuais obtidos no processo de predição dos casos com o uso das duas redes neurais (RNA 29_sHIS e RNA 40_geral) para Paraty e Bom Jesus da Lapa. Os resultados obtidos com a rede neural RNA 29_sHIS para Paraty são similares aos resultados obtidos quando os 250.000 casos da base de dados foram avaliados, apresentando os menores valores para a mediana (3,8%), primeiro quartil (1,9%) e terceiro quartil (6,4%), ou seja, a predição com o uso da RNA 29_sHIS apresentou em 50% dos casos erro percentual entre 1,9% e 6,4% para esta cidade. Outra análise indicou que em 99,2% dos casos o erro percentual foi inferior a 15%. Os resultados com a rede neural RNA 29_sHIS para Bom Jesus da Lapa mostraram um acréscimo nos erros

percentuais (mediana=5,5%, primeiro quartil=2,5% e terceiro quartil=9,6%), mas evidenciaram que esta rede tem um bom resultado mesmo para climas com altas taxas de radiação (90,3% dos casos apresentaram erro percentual inferior a 15%). Os resultados para a rede neural RNA 40_geral mostraram que esta rede tem um desempenho inferior ao da rede RNA 29_sHIS , pois os erros percentuais obtidos, foram superiores (mediana de 9,1% para Paraty e 11,0% para Bom Jesus da Lapa). Tal redução no desempenho também pode ser confirmada quando a análise do percentual de casos com erro inferior a 15% foi realizada, resultando em 76,0% dos casos para Paraty e 72,0% dos casos para Bom Jesus da Lapa.

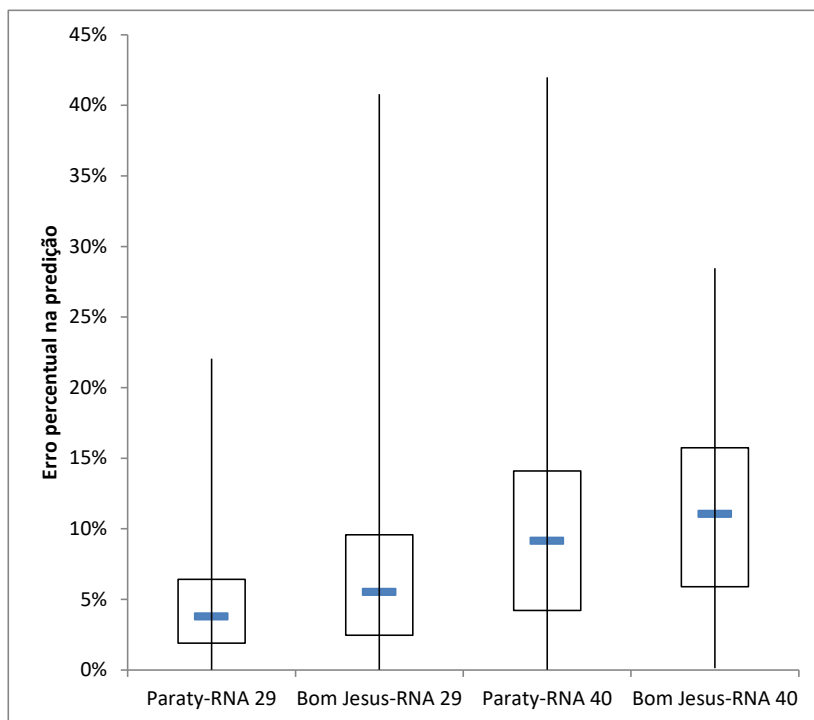


Figura 24 – Diagrama de caixa (*boxplot*) para o erro percentual da predição de consumo com as redes neurais RNA 29_sHIS e RNA 40_geral, para Paraty e Bom Jesus da Lapa.

Os resultados ilustrados através da Figura 25 para a rede RNA 29_sHIS e da Figura 26 para a rede RNA 40_geral, também evidenciam o desempenho superior da rede neural RNA 29_sHIS no processo de

predição de consumo de sistemas de climatização para as cidades de Paraty e Bom Jesus da Lapa. Conclui-se que o desempenho da rede RNA 29_sHIS não é afetado pelo perfil de radiação da cidade para qual se deseja estimar o consumo, mas o mesmo não ocorre para a rede RNA 40_geral. Conforme já mencionado, tal fato ocorre porque a radiação tem impacto sobre a carga térmica, que é uma variável de entrada da rede RNA 29_sHIS, e portanto tal influência foi computada quando da obtenção da carga térmica. Na rede RNA 40_geral, a carga térmica é estimada pela rede a partir dos dados construtivos da edificação e do clima, e neste caso maiores erros são obtidos pois o indicador climático (CEH) não considera o perfil de radiação em seus cálculos.




Figura 25 – Consumo predito versus consumo simulado – rede RNA29_sHIS.

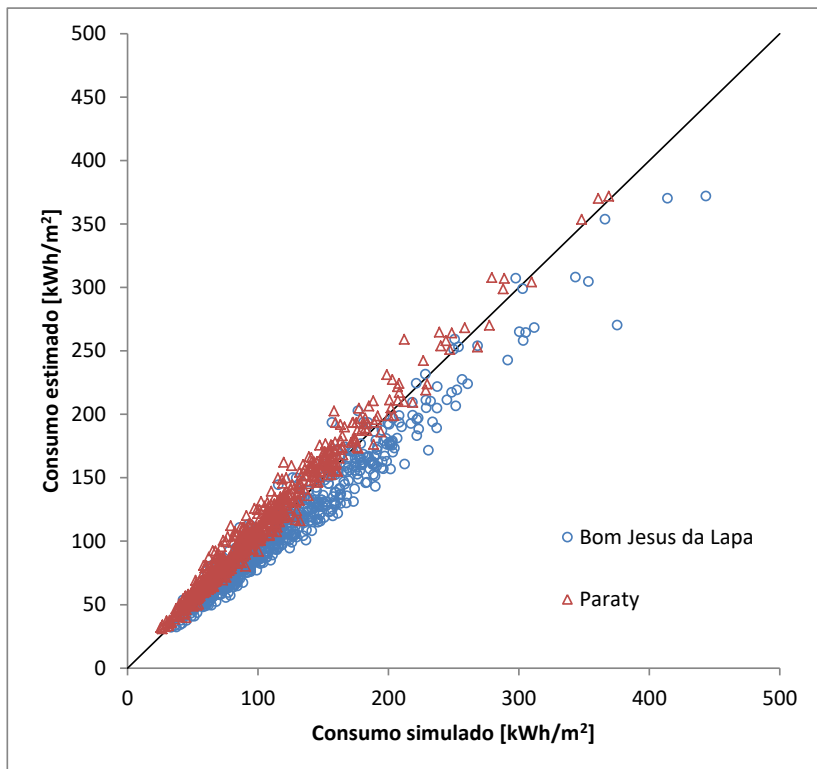


Figura 26 – Consumo predito versus consumo simulado – rede RNA 40_geral.

5. CONCLUSÕES

O objetivo principal deste trabalho foi desenvolver um modelo simplificado para prever o consumo anual de energia de sistemas de ar condicionado do tipo água gelada em edifícios de escritórios. Através da revisão bibliográfica verificou-se que a maioria dos estudos nesta área desenvolve modelos simplificados para avaliar o desempenho da edificação estimando a carga térmica de resfriamento/aquecimento, ao invés de estimar o consumo do sistema. Sendo assim, buscou-se avançar nesta área com o desenvolvimento de um método que estime o consumo de sistemas de climatização a partir do conhecimento da carga térmica integrada anual de resfriamento da edificação, das características do sistema climatização, e do clima. O consumo de aquecimento foi desconsiderado por ser insignificante nas edificações comerciais brasileiras. O conceito de método híbrido foi adotado, onde redes neurais artificiais foram treinadas a partir de uma base de dados obtida através da realização de simulações de edificações com sistemas de climatização do tipo água gelada.

Por se tratar de um método simplificado, houve a necessidade da escolha de um indicador para caracterizar o clima da cidade onde a edificação se encontra construída. Assim, o arquivo climático, usualmente utilizado em métodos complexos de engenharia (simulação de edificações, por exemplo), é substituído por apenas um indicador climático. E este indicador se constitui em um dos neurônios de entrada da rede neural do metamodelo. A primeira etapa da pesquisa foi avaliar os indicadores usualmente utilizados em modelos simplificados, propor um novo indicador e avaliar o seu desempenho, e determinar um zoneamento bioclimático brasileiro com base no indicador escolhido.

Os indicadores climáticos mais usuais (CDD e CDH) utilizam somente a temperatura de bulbo seco em seus cálculos, desconsiderando a presença da fração de calor latente presente na carga térmica de resfriamento das edificações. Esta limitação tem uma influência nos modelos de previsão de consumo de energia em edificações que empregam estes indicadores em climas quentes e úmidos, visto que a energia consumida no processo de desumidificação nestes climas é significativa.

O indicador proposto neste trabalho (CEH) utiliza a entalpia em seus cálculos, além da temperatura de bulbo seco, buscando assim considerar a fração de calor latente da carga térmica de resfriamento. Os resultados da análise de desempenho demonstraram que este novo indicador é mais preciso do que o indicador CDH, visto que o erro padrão da regressão linear, utilizada para relacionar a carga térmica

integrada anual de resfriamento e o indicador, reduziu 21,5% com o uso do CEH no lugar do CDH. A análise realizada para determinar quais os valores que deveriam ser empregados para a temperatura base e entalpia base, permitiu concluir que os valores mais apropriados são 18°C e 35 kJ/kg, respectivamente. Uma pequena variação em torno destes valores não apresentou mudança significativa nos resultados do coeficiente de determinação (R^2) das regressões lineares realizadas. O cálculo dos indicadores, considerando os valores de entalpia e temperatura somente quando o sistema de climatização está operando, não resultaram na melhoria de desempenho destes indicadores. Portanto, o cálculo considerando todas as horas presente no arquivo climático foi adotado como padrão na definição do indicador CEH. Este procedimento de cálculo também é mais simples.

O estudo do desempenho de indicadores climáticos, inicialmente realizado para 20 cidades, foi ampliado para 407 cidades brasileiras, para as quais estão disponíveis os seus respectivos arquivos climáticos. Além do novo indicador CEH, outro indicador que emprega a entalpia em seus cálculos (CDH_H) foi avaliado. Novamente, os resultados obtidos com o novo indicador foram mais precisos (erro padrão 13% menor). Conclui-se, portanto, que este novo indicador é mais adequado para ser utilizado como indicador climático em modelos de previsão de carga térmica de resfriamento ou de consumo de edificações brasileiras climatizadas artificialmente.

Finalmente para validar o desempenho do novo indicador climático (CEH), outras edificações, distintas da edificação modelo empregada nas análises anteriores, foram simuladas para a obtenção da carga térmica integrada anual de resfriamento. E, novamente, regressões lineares foram obtidas para relacionar esta carga térmica e os indicadores climáticos. Três foram os indicadores analisados: CDH, CDH_H e CEH. Os resultados demonstraram novamente que o CEH é mais preciso que os demais indicadores, visto que o erro padrão reduziu 46% em média quando o CDH_H foi utilizado no lugar do CDH, e 29% quando o CEH foi utilizado no lugar do CDH_H .

Devido ao cálculo de CEH ser a soma da diferença de entalpias de um arquivo climático, valores similares de CEH podem ser obtidos de climas com diferentes distribuições de frequência de entalpia. Mesmo assim, os resultados mostraram que o indicador CEH é eficaz ao relacionar o clima com a carga térmica de resfriamento anual da edificação. Trabalhos futuros poderão investigar como caracterizar a diferença entre estes climas que tem valores de CEH similares.

A segunda etapa da pesquisa consistiu em definir quais seriam as variáveis cujos valores sofreriam variação para obtenção dos casos a serem simulados no processo de criação da base de dados. Uma análise de sensibilidade pelo método Sobol foi realizada considerando inicialmente 18 variáveis para caracterizar a edificação, 1 variável para caracterizar o clima e 11 variáveis para caracterizar o sistema de climatização. Os resultados demonstraram que alterações nos valores das características térmicas das paredes e telhado (absortância, transmitância e capacidade térmica) influenciam menos nos valores de carga térmica de resfriamento e consumo do sistema de climatização, do que alterações em outras características da edificação. Da mesma forma, o uso de ciclo noturno e do reset da temperatura da água gelada também apresentaram menor influência no consumo, quando comparados com as outras variáveis utilizadas para caracterizar o sistema de climatização. Sendo assim, a análise de sensibilidade permitiu reduzir em 30% o número de variáveis (de 30 para 21) que foram parametrizadas para obtenção da base de dados.

Após a realização de uma amostra de 250.000 casos pelo método Hipercubo Latino, a simulação destes casos foi conduzida. Os dados destas simulações, depois de um processo de pré-processamento, constituíram a base de dados a partir da qual redes neurais artificiais foram treinadas para prever o consumo anual de sistemas de climatização. O uso de todos os dados para este treinamento é inviável devido ao tempo de processamento computacional, sendo assim, um estudo foi realizado para definir qual o tamanho da amostra a ser empregado. Os resultados deste estudo permitiram concluir que o tempo de processamento tem relação linear com o tamanho da amostra, e que redes neurais artificiais apresentam bom desempenho quando treinadas com um tamanho de amostra calculado estimando a média da população com níveis de confiança igual a 95% e margem de erro igual a 1% do desvio padrão da variável de interesse. Com base nestes resultados, a presente pesquisa empregou no treinamento das redes neurais artificiais um tamanho de amostra correspondente à 36.594 casos.

A arquitetura da rede neural artificial foi inicialmente definida com 18 neurônios na camada de entrada (Tabela 21), 13 neurônios na camada interna e 1 neurônio na camada de saída. O aumento no número de neurônios na camada interna resultou em melhorias nos indicadores de desempenho da rede (R^2 , RMSE e NRMSE), mas levou ao aumento do tempo de processamento. Sendo assim, o índice síntese de desempenho global (IDG) foi empregado para definir qual o número de neurônios na camada interna que apresentava melhor custo-benefício.

Os resultados mostraram que tal situação ocorreu quando a rede neural tem 32 neurônios na camada interna, ou seja, uma relação de $1,7 \times N$ (onde N é a soma do número de neurônios das camadas de entrada e de saída). Tal rede foi denominada de rede base RNA 32. Ao analisar os erros na predição do consumo com o uso desta rede, verificou-se que erros percentuais acima de 40% somente ocorriam nos casos onde o indicador CEH tinha valores inferiores a 50.000, o que levou a impor esta restrição ao uso do metamodelo (mínimo CEH = 50.000).

O desempenho da rede RNA 32, que emprega a carga térmica da edificação e seu histograma como variáveis de entrada, foi comparado com o desempenho de uma rede que utiliza as características da edificação ao invés da carga térmica (RNA 40_geral). O desempenho obtido com estas duas redes neurais, na predição dos casos da base de dados, foi similar (NRMSE=0,062348 para RNA 32, e NRMSE=0,054504 para RNA 40_geral), mostrando que a carga térmica integrada anual pode ser utilizada para representar a edificação no metamodelo. Outro estudo que consistiu em treinar duas redes neurais, uma para os casos com *chiller* a ar (RNA 32_ar) e outra para os casos com *chiller* a água (RNA 32_água), demonstrou que há ganho de desempenho com a rede RNA 32_ar (redução de 20% no NRMSE, quando comparado com a rede base RNA 32) e perda com a rede RNA_água (aumento de 5,4% no NRMSE). Optou-se nesta pesquisa por manter uma única rede para ambos os casos (RNA 32), mas para trabalhos futuros entende-se que a melhoria no desempenho justifique o uso de redes separadas.

A influência da inclusão, exclusão ou alteração de variáveis na camada de entrada da rede neural artificial também foi avaliada. Como resultado desta avaliação duas novas redes neurais foram obtidas: a RNA 35_COP que resultou da substituição do IPLV pelos quatro valores de COP, e a RNA 29_sHIS que resultou da exclusão das quatro variáveis que representavam o histograma de frequência da carga térmica de resfriamento. Estas redes, juntamente com a rede base (RNA 32), apresentaram desempenhos semelhantes na predição dos casos da base de dados (NRMSE em torno de 0,064, e mediana do erro percentual próxima a 3,6%).

Na etapa final desta pesquisa, três redes neurais artificiais (RNA 32, RNA 35_COP e RNA 29_sHIS) foram utilizadas para predizer o consumo anual do sistema de climatização de 65.697 novos casos. Estes casos foram gerados com valores distintos daqueles empregados na etapa de criação da base de dados, e por isso foram denominados de casos não vistos. A rede neural mais simplificada (RNA 29_sHIS)

apresentou melhor desempenho na predição do consumo destes casos. Sendo assim, concluiu-se que este metamodelo, composto por 14 neurônios na camada de entrada (variáveis de 1 à 14 na Tabela 21), 29 neurônios na camada interna e 1 neurônio na camada de saída, deveria ser escolhido como metamodelo final deste trabalho. Tal decisão considerou que esta rede apresentou bom desempenho ao predizer o consumo anual do sistema de climatização dos casos da base de dados ($R^2=0,9858$ e $NRMSE=0,067961$), e também ao predizer os casos não vistos ($R^2=0,9789$ e $NRMSE=0,063788$), desempenho similar aos outros metamodelos analisados, mas com uma arquitetura menos complexa.

Uma última avaliação consistiu em verificar a influência da radiação no desempenho dos metamodelos. Os resultados demonstraram que o metamodelo final (RNA 32) apresenta bom desempenho independente do perfil de radiação da cidade onde a edificação se encontra, visto que a carga térmica é uma variável de entrada deste metamodelo, e portanto, a radiação já é considerada no momento da determinação do valor desta carga térmica. Mas para os casos onde a estimativa de carga térmica encontra-se incorporada ao metamodelo (RNA 40_geral, por exemplo), os resultados demonstraram que o desempenho do metamodelo é influenciado pelo perfil de radiação, visto que o indicador climático adotado (CEH) não considera tal variável em seus cálculos.

Esta pesquisa foi conduzida para sistema de climatização do tipo água gelada e assim o metamodelo obtido não se aplica a outros tipos de sistemas de climatização (expansão direta, fluxo de refrigerante variável, entre outros). Geometrias não retangulares, perfis de uso não regulares, variação ocupacional e suposta influência do comportamento dos ocupantes da edificação não foram consideradas, caracterizando assim outras limitações do metamodelo. Pesquisas futuras poderão ser desenvolvidas para os outros sistemas de climatização. Resultados obtidos, usando o metamodelo aqui desenvolvido, poderão ser comparados com resultados de outros modelos simplificados de predição de consumo de energia de sistemas de climatização. Trabalhos futuros poderão também desenvolver indicadores climáticos que considerem a radiação solar em seus cálculos, para serem empregados em metamodelos de estimativa de carga térmica.

REFERÊNCIAS

- AHMAD, M.W., MOURSHED, M., YUCE,B., REZGUI, Y. Computational intelligence techniques for HVAC systems: a review. **Building Simulation**, v. 9, p. 359-398, 2016.
- AHMAD, M.W., MOURSHED, M., REZGUI, Y. Trees vs Neurons: Comparison between random forest and ANN for high-resolution prediction of building energy consumption. **Energy and Buildings**, v.147, p. 77-89, 2017.
- AHRI Standard 550/590. **2011 Standard for performance rating of water-chilling and heat pump water-heating packages using the vapor compression cycle**, Air-Conditioning, Heating, Refrigeration Institute, Arlington, VA, USA, 2011.
- AL-HOMOUD, M.S. Computer-aided building energy analysis techniques. **Building and Environment**, v. 36, p. 421-433, 2001.
- ANNUAL ENERGY OUTLOOK 2018, Table: Energy Consumption by Sector and Source, Case: Reference case, Region: United States disponível em: <https://www.eia.gov/outlooks/aeo/data/browser/#/?id=2-AEO2018®ion=1-0&cases=ref2018&start=2016&end=2050&f=A&linechart=ref2018-d121317a.3-2-AEO2018.1-0~ref2018-d121317a.9-2-AEO2018.1-0&map=ref2018-d121317a.4-2-AEO2018.1-0&ctype=linechart&sourcekey=0> , acessado em: 08 de janeiro de 2019.
- ASHRAE, **Handbook 2013: Fundamentals**, SI edition, American Society of Heating, Refrigeration and Air Conditioning Engineers, 2013.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 15.220: Desempenho térmico de edificações**. Rio de Janeiro, 2005.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 16.401: Instalações de ar-condicionado – Sistemas centrais e unitários**. Rio de Janeiro, 2008.
- AUGENBROE, G.; ZHANG Y.; KHAZAI, J.; SU, H.; SUN, Y.; LEE, B.D., WU, C.F.J. Implications of the uncoupling of building and HVAC simulation in the presence of parameter uncertainties. **Proceedings of**

the 13th Conference of International Building Performance Simulation Association. França, 26 a 28 de Agosto de 2013.

BEN-NAKHI, A.E., MAHMOUD, M.A. Cooling load prediction for buildings using general regression neural networks. **Energy Conversion & Management**, v. 45, p. 2127-2141, 2004.

BLOOMFIELD, C.; BANNISTER, P.; AUSTRALIA, E. Energy and water performance benchmarking in the retail sector – NABERS shopping centres. **Proceedings of the 2010 ACEEE Summer Study on Energy Efficiency in Buildings**, 2010.

BORGSTEIN, E.H.; LAMBERTS, R. Developing energy consumption benchmarks for buildings: Bank branches in Brazil. **Energy and Buildings**, v.82, p 82-91, 2014.

BOX, G.E.P.; COX, D.R. Na analysis of transformations. **Journal of the Royal Statistical Society**, v.26, p.211-252, 1964.

BRAUN, J.E., CHATURVEDI, N. An inverse gray-box model for transient building load prediction. **HVAC&R Research**, v. 8, p. 73-99, 2002.

BSRIA World Air Conditioning, disponível em: <https://www.bsria.com/news/article/world-air-conditioning-market-grows-thanks-to-hot-spots/>, acessado em: 24 de setembro de 2016.

BSRIA World Air Conditioning, disponível em: <https://www.bsria.co.uk/news/article/bsria-global-air-conditioning-study-shows-contraction-in-2016/>, acessado em: 20 de junho de 2017.

BSRIA World Air Conditioning, disponível em: <https://www.bsria.co.uk/news/article/bsria-global-air-conditioning-study-shows-recovery-in-2017/>, acessado em: 24 de outubro de 2018.

CAIXA ECONÔMICA FEDERAL, **Selo Caixa Azul: Boas práticas para habitação mais sustentável**. Coordenadores Vanderley Moacys John, Racine Tadeu Araújo Prado. São Paulo, Páginas & Letras – Editora e Gráfica, 2010.

CARLO, J. **Desenvolvimento de Metodologia de Avaliação da Eficiência Energética do Envoltório de Edificações Não-residenciais**.

2008. 193 f. Tese (Doutorado em Engenharia Civil)—Programa de Pós Graduação em Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2008.

CARLO, J.; LAMBERTS, R. Development of envelope efficiency labels for commercial buildings: Effect of different variables on electricity consumption. **Energy and Buildings**, v. 40, n. 11, p. 2002–2008, jan. 2008.

CATALINA, T. Building design optimization using a new prediction model for the heating energy consumption. **Mathematical Modeling in Civil Engineering 4**, 2012.

CECCHINATO, L. Part load efficiency of packaged air-cooled water chillers with inverter driven scroll compressors. **Energy Conversion and Management**, v.51, p.1500-1509, 2010.

CHAE, Y.T., HORESH, R., HWANG, Y., LEE, Y.M. Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings. **Energy and Buildings**, v. 111, p-184-194, 2016.

CHO, J; SHIN, S.; KIM, J.; HONG H. Development of an energy evaluation methodology to make multiple predictions of the HVAC&R system energy demand for office buildings. **Energy and Buildings**, v.80, p. 169-183, 2014.

CHOU, J. S.; BUI, D. K. Modeling heating and cooling loads by artificial intelligence for energy-efficient building design. **Energy and Buildings**, v. 82, p. 437–446, 2014.

CHUA, K. J.; CHOU, S. K., YANG, W.M., YAN, J. Achieving better energy-efficient air conditioning – A review of technologies and strategies. **Applied Energy**, v. 104, p. 87–104, 2013.

CORRADO, V.; MECHRI, H.E. Uncertainty and sensitivity analysis for building energy rating. **Journal of Building Physics**, v.33 p125-156, 2009.

CRAWLEY, D. B, HAND, J. W., KUMMERT, M., GRIFFITH, B. T. Contrasting the capabilities of building energy performance simulation programs. **Building and Environment**. ScienceDirect, v. 43, p. 661-673, 2008.

DAUT, M.A.M., HASSAN, M.Y., ABDULLAH, H., RAHMAN, H.A., ABDULLAH, M.P., HUSSIN, F. Building electrical energy consumption forecasting analysis using conventional and artificial intelligence methods: A review. **Renewable and Sustainable Energy Reviews**, v.70, p. 1108-1118, 2017.

DE WILDE, P.;TIAN, W. Identification of key factors for uncertainty in the prediction of the thermal performance of an office building under climate change. **Proceedings of Eleventh International IBPSA Building Simulation Conference**, 2009.

DJUNAEDY, E., VAN DER WYMELENBERG, K., ACKER, B., THIMMANA, H. Oversizing of HVAC system: Signatures and penalties. **Energy and Buildings**, v. 43, p. 468–475, 2011.

DONG, B., CAO, C., LEE, S.E. Applying support vector machines to predict building energy consumption in tropical region. **Energy and Buildings**, v.37, p.545-553, 2005.

DONG, Q., XING, K., ZHANG, H. Artificial neural network for assessment of energy consumption and cost for cross laminated timber office building in severe cold regions. **Sustainability**, v.10, p.1-15, 2018.

DUNN, G., KNIGHT, I. Small power equipment loads in UK office environments. **Energy and Buildings**, v. 37, p. 87–91, 2005.

EKICI, B.B., AKSOY, U.T. Prediction of building energy consumption by using artificial neural networks. **Advances in Engineering Software**, v.40, p-356-362, 2009.

ELETROBRÁS. Relatório da pesquisa de posse de equipamentos e hábitos de uso – classe comercial – AT – ano base 2005, disponível em <http://www.procelinfo.com.br/main.asp?View=%7B5A08CAF0-06D1-4FFE-B335-95D83F8DFB98%7D&Team=¶ms=itemID=%7B9B879391-1D29-4834-8554-34E61FBD1AA9%7D%3B&UIPartUID=%7B05734935-6950-4E3F-A182-629352E9EB18%7D>, 2008.

ELLIS, M. W.; MATHEWS, E. H. A new simplified thermal design tool for architects. **Building and Environment**, v. 36, n. 9, p. 1009-1021, 2001. ISSN 0360-1323.

ENERGYSTAR, **Portfolio Manager Technical Reference: Climate and Weather.** Disponível em <https://portfoliomanager.energystar.gov/pdf/reference/Climate%20and%20Weather.pdf>, acessado em 24 de outubro de 2018.

ENTERIA, N., MIZUTANI, K. The role of the thermally activated desiccant cooling technologies in the issue of energy and environment. **Renewable and Sustainable Energy Reviews**, v. 15, p. 2095-2122, 2011.

EPE - Empresa de Pesquisa Energética. **Balço Energético Nacional 2017: Ano base 2016.** Rio de Janeiro: EPE, 2017. Disponível em: http://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-46/topico-82/Relatorio_Final_BEN_2017.pdf, acessado em: 24 de outubro de 2018.

FAHLMAN, S.E. An empirical study of learning speed in back-propagation networks, 1988.

FARIA, H.B., MELO E SOUZA, S., SALIBY, E. Análise de risco: uma comparação de diferentes métodos de amostragem. **XXIII Encontro da Associação Nacional de Pós-Graduação em Administração-ENANAP**, 1999.

FISCHER, D.E., TAYLOR, R.D., BUHL, F., LIESEN, R.J., STRAND, R.K. 1999. A Modular, Loop-Based Approach to HVAC Energy Simulation and Its Implementation in EnergyPlus. **Proceedings of Building Simulation 99**, Vol. 3, pp. 1245-1252, 1999.

FORRESTER, A.I.J.; SOBESTER, A.; KEANE, A.J. **Engineering design via surrogate modelling: a practical guide.** John Wiley & Sons, 2008.

FOUCQUIER, A.; ROBERT, S.; SUARD, F.; STÉPHAN, L.; JAY, A. State of the art in building modelling and energy performances prediction: A review. **Renewable and Sustainable Energy Reviews**, v. 23, p. 272–288, 2013.

FREIRE, R.Z., OLIVEIRA, G.H.C., MENDES, N. Development of regression equations for predicting energy and hygrothermal

performance of buildings. **Energy and Buildings**, v. 40, p. 810-820, 2008.

FUMO, N. A review on the basics of building energy estimation. **Renewable and Sustainable Energy Reviews**, v. 31, p. 53–60, 2014.

GANG, W., WANG, S., SHAN, K., GAO, D. Impacts of cooling load calculation uncertainties on the design optimization of building cooling systems. **Energy and Buildings**, v. 94, p. 1-9, 2015.

GEISTER, W.R., THOMPSON, M. A closer look at chiller ratings. **ASHRAE Journal**, p. 22-32, 2009.

HONG, T.; CHOU, S.K.; BONG, T.Y. Building simulation: an overview of developments and information sources. **Building and Environment**, v. 35, p. 347-361, 2000.

HOPFE, C.J.; HENSEN, J.L.M. Uncertainty analysis in building performance simulation for design support. **Energy and Buildings**, v.43, p.2798-2805, 2011.

HUANG, Y.J.; RITSCHARD, R.; BULL, J.; CHANG, L. **Climate indicators for estimating residential heating and cooling loads**. Lawrence Berkeley Laboratory, Report LBL-21101, Berkeley, CA, 1986.

HUNN, B.D. **Fundamentals of building energy dynamics**. MIT, 1996.

Instituto Nacional de Metrologia, Normalização e Qualidade Industrial (INMETRO). 2010. Portaria 372, de 17 de setembro de 2010. Requisitos Técnicos da Qualidade para o Nível de Eficiência Energética de Edifícios Comerciais, de Serviços e Públicos. Rio de Janeiro, Brazil.

Instituto Nacional de Metrologia, Normalização e Qualidade Industrial (INMETRO). 2018. Portaria 248, de 10 de julho de 2018. Aperfeiçoamento do Regulamento Técnico da Qualidade para a Classe de Eficiência Energética de Edifícios Comerciais, de Serviços e Públicos. Rio de Janeiro, Brazil.

International Energy Agency (IEA). **The Future of Cooling – Opportunities for Energy-Efficient Air Conditioning**; OECD/IEA, Paris, França, 2018.

ISHIGAMI, T., HOMMA, T. An important quantification technique in uncertainty analysis for computer models. **Proceedings of the First International Symposium on Uncertainty Modelling an Analysis**, p. 398-403, 1990.

ISRAEL, G.D. Determining sample size. Fact Sheet PEOD-6, Agricultural Education and Communication Department, Florida Cooperative Extension Service, Institute of Food an Agricultural Sciences, University of Florida, 1992.

KALOGIROU, S.A. Applications of artificial neural-networks for energy systems. **Applied Energy**, v. 67, p. 17-35, 2000.

KALOGIROU, S.A. Artificial neural networks in renewable energy systems applications: a review. **Renewable & Sustainable Energy Reviews**, v. 5, p.373-401, 2001.

KALOGIROU, S.A. Artificial neural networks in energy applications in buildings. **International Journal of Low Carbon Technologies**, p.201-216, 2006.

KIM, J. Estimating classification error rate: Repeated cross-validation, repeated hold-out and bootstrap. **Computational Statistics and Data Analysis**, v. 53, p.3735-3745, 2009.

KLIMCZAK, M., BOJARSKI, J., ZIEMBICKI, P., KESKIEWICZ, P. Analysis of the impact of simulation model simplifications on the quality of low-energy buildings simulation results. **Energy and Buildings**, v.169, p. 141-147, 2018.

KOROLIJA, I., MARJANOVIC-HALBURD, L., ZHANG, Y., HANBY, V.I. Influence of building parameters and HVAC systems coupling on building energy performance. **Energy and Buildings**, v. 43, p. 1247-1253, 2011.

KOROLIJA, I., MARJANOVIC-HALBURD, L., ZHANG, Y., HANBY, V.I. UK office buildings archetypal model as methodological approach in development of regression models for predicting building energy consumption from heating and cooling demands. **Energy and Buildings**, v. 60, p. 152-162, 2013.

KOROLJA, I., MARJANOVIC-HALBURD, L., ZHANG, Y., HANBY, V.I. Regression models for predicting UK office building energy consumption from heating and cooling demands. **Energy and Buildings**, v. 59, p. 214-227, 2013.

KRESE, G.; PREK, M.; BUTALA, V. Incorporation of latent loads into the cooling degree days concept. **Energy and Buildings**, v. 43, p.1757-764, 2011.

KUHN, M. Building predictive models in R using the caret package. **Journal of Statistical Software**, v.28, p.1-26, 2008.

KUHN, M., JOHNSON, K. **Applied Predictive Modeling**. New York: Springer, 2013.

KUHN, M., JOHNSON, K. **Blog do livro Applied Predictive Modeling**. Disponível em: <http://appliedpredictivemodeling.com/blog/2014/11/27/vpuig01pqbklmi72b8lcl3ij5hj2qm>, acessado em 25 de outubro de 2018.

KUMAR, R., AGGARWAL, R.K., SHARMA, J.D. Energy analysis of a building using artificial neural network: A review. **Energy and Buildings**, v. 65, p. 352-358, 2013.

LAM, J.C., HUI, S.C.M., CHAN, A.L.S. Regression analysis of high-rise fully air-conditioned office buildings. **Energy and Buildings**, v. 26, p. 189-197, 1997.

LAM, J.C., WAN, K.K.W., LAN, T.N.T., WONG, S.L. An analysis of future building energy use in subtropical Hong Kong. **Energy**, v. 35, p. 1482-1490, 2010.

LEE, W, YIK, F.W.H., BURNETT, J. Simplifying energy performance assessment in the Hong Kong Building Environmental Assessment Method. **Building Services Engineering Research and Technology**, v. 22, p. 113-132, 2001.

LI, K., SU, H., CHU, J. Forecasting building energy consumption using neural networks and hybrid neuro-fuzzy system: A comparative study. **Energy and Buildings**, v.43, p.2893-2899, 2011.

LI, Z., HUANG, G. Re-evaluation of building cooling load prediction models for use in humid subtropical area. **Energy and Buildings**, v. 62, p. 442-449, 2013.

MACDONALD, I.A. Comparison of sampling techniques on the performance of Monte-Carlo based sensitivity analysis. **Proceedings of Eleventh International IBPSA Building Simulation Conference**, 2009.

MAZZAFERRO, L., SORGATO, M.J., VERSAGE, R., MELO, A.P., LAMBERTS, R. Manual de simulação computacional de edifícios com o uso do pré-processador Slab no programa EnergyPlus. Disponível em: http://www.labeee.ufsc.br/sites/default/files/publicacoes/relatorios_pesquisa/ECV4202_Manual_Slab.pdf, acessado em 10 de abril de 2019.

MCKAY, M.D., BECKMAN, R.J., CONOVER, W.J. A comparison of three methods for selecting values of input variables in the analysis of output from a computer code. **Technometrics**, v. 21, p. 239-245, 1979.

MCQUISTON, F.C.; PARKER, J.D.; SPITLER, J.D. **Heating, ventilation and air conditioning: analysis and design**. John Wiley & Sons, 2005.

MECHRI, H.E.; CAPOZZOLI, A.; CORRADO, V. USE of the ANOVA approach for sensitive building energy design. **Applied Energy**, v.87, p.3073-3083, 2010.

MEISSNER, J.W., ABADIE, M. O., MOURA, L.M., MENDONÇA, K.C., MENDES, N. Performance curves of room air conditioners for building energy simulation tools. **Applied Energy**, v. 129, p. 243-252, 2014.

MELO, A.P. **Desenvolvimento de um método para estimar o consumo de energia de edificações comerciais através da aplicação de redes neurais**. 2012. 189 f. Tese (Doutorado em Engenharia Civil)—Programa de Pós Graduação em Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2012.

MENA, R., RODRÍGUEZ, F., CASTILLA, M., ARAHAL, M.R. A prediction model based on neural networks for the energy consumption of a bioclimatic building. **Energy and Buildings**, v.82, p-142-155, 2014.

MOLINARO, A. M.; SIMON, R.; PFEIFFER, R. M. Prediction error estimation: a comparison of resampling methods. **Bioinformatics**, v. 21, p.2201-3307, 2005.

MOON, H.J. Uncertainty analysis in mould spore transportation and its application in an existing building. **Indoor and Built Environment**, v.19, p.356-365, 2010.

NGUYEN, A., REITER, S., RIGO, P. A review on simulation-based optimization methods applied to building performance analysis. **Applied Energy**, v. 113, p. 1043-1058, 2014.

O'NEILL, Z., NARAYANAN, S., BHAHME, R. Model-based thermal load estimation in buildings. **Proceedings of SimBuild**, p. 474-481, 2010.

OURGHI, R.; AL-ANZI, A.; KRARTI, M. A simplified analysis method to predict the impact of shape on annual energy use for office buildings. **Energy Conversion and Management**, v. 48, p. 300-305, 2007

PACHECO, R.; ORDÓÑEZ, J.; MARTÍNEX, G. Energy efficient design of building: A review. **Renewable and Sustainable Energy Reviews**, v. 16, p. 3559-3573, 2012.

PANCHAL, G.; GANATRA, A.; KOSTA, Y.P.; PANCHAL, D. Behaviour analysis of multilayer perceptrons with multiple hidden neurons and hidden layers. **International Journal of Computer Theory and Engineering**, v.3, p.332-337, 2011.

PAPAKOSTAS, K.; KYRIAKIS, N. Heating and cooling degree-hours for Athens and Thessaloniki, Greece. **Renewable Energy**, v.30, p. 1873-1880, 2005.

PÉREZ-LOMBARD, L.; ORTIZ, J.; POUT, C. A review on buildings energy consumption information. **Energy and Buildings**, v. 40, p. 394-398, 2008.

PÉREZ-LOMBARD, L.; ORTIZ, J.; MAESTRE, I.R. The map of energy flow in HVAC systems. **Applied Energy**, v. 88, p. 5020-5031, 2011a.

PÉREZ-LOMBARD, L.; ORTIZ, J.; CORONE, J.F., MAESTRE, I.R. A review of HVAC systems requirements in building energy regulations. **Energy and Buildings**, v. 43, p. 255-268, 2011b.

PINO-MEJÍAS, R., PÉREZ-FARGALLO, A., RUBIO-BELLIDO, C., PULIDO-ARCAS, J.A., Comparison of linear regression and artificial neural networks models to predict heating and cooling energy demand, energy consumption and CO₂ emissions. **Energy**, v.118, p. 24-36, 2017.

PLATON, R., DEHKORDI, V.R., MARTEL, J. Hourly prediction of a building's electricity consumption using case-based reasoning, artificial neural networks and principal component analysis. **Energy and Buildings**, v.92, p-10-18, 2015.

PROCEL – Programa Nacional de Conservação de Energia Elétrica, disponível em:
<http://www.eletrobras.com/elb/main.asp?TeamID={A8468F2A-5813-4D4B-953A-1F2A5DAC9B55}>, acessado em: 26 de outubro de 2013.

R, Core Team. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria, 2014. Disponível em: <http://www.r-project.org>

RIPLEY, B; VENABLES, W. **nnet: Feed-forward neural networks and multinomial log-linear models**. R Package version 7.3-8. 2014.

RORIZ, M. Uma proposta de revisão do zoneamento bioclimático brasileiro, disponível em:
http://www.labee.ufsc.br/sites/default/files/projetos/Proposta_Revisao_Zoneamento_Bioclimatico.pdf, acessado em: 12 de dezembro de 2018.

ROTH, K. W., WESTPHALEN, D., DIECKMANN, J., HAMILTON, S.D., GOETZLER, W. Energy Consumption Characteristics of Commercial Building HVAC Systems. Volume III: Energy Savings Potential. TIAX LLC. **Proceedings...** Cambridge, 2002.

SAILOR, D.J.; MUÑOZ, R. Sensitivity of electricity and natural gas consumption to climate in the USA – methodology and results for eight states. **Energy**, v.22, p.987-998, 1997.

SAILOR, D.J. Relating residential and commercial sector electricity loads to climate-evaluating state level sensitivities and vulnerabilities. **Energy**, v.26, p. 645-657, 2001.

SANTELLI, A. Making best use of model evaluations to compute sensitivity indices. **Computer Physics Communications**, v.145, p. 280-297, 2002.

SALTELLI, A.; TARANTOLA, S.; CAMPOLONGO, F.; RATTO, M. **Sensitivity analysis in practice: a guide to assessing scientific models**. John Wiley & Sons, 2004.

SANDER, D.M., CORNICK, S., NEWSHAM, G.R., CRAWLEY, D.B. Development of a simple model to relate heating and cooling energy to building envelope thermal characteristics. **Proceedings of the Building Simulation'93 Conference**. 1993.

SANTANA, M.V. **Influência de parâmetros construtivos no consumo de energia de edifícios de escritório localizados em Florianópolis-SC**. 2006. 196 f. Dissertação (Mestrado em Engenharia Civil)—Programa de Pós Graduação em Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2006.

SCHIBUOLA, L., SCARPA, M. On-field validation of a seasonal performance calculation method for chillers in buildings. **Energy Conversion and Management**, v. 85, p. 62-69, 2014.

SHIN, M.; DO, S.L. Prediction of cooling energy use in buildings using the enthalpy-based cooling degree days method in a hot and humid climate. **Energy and Buildings**, v. 110, p 57-70, 2016.

SIGNOR, R. **Análise de regressão do consumo de energia elétrica frente a variáveis arquitetônicas para edifícios comerciais climatizados em 14 capitais brasileiras**.1999. 122 f. Dissertação (Mestrado em Engenharia Civil). Programa de Pós Graduação em Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 1999.

SIMLAB V2.2, **Simulation environment for uncertainty and sensitivity analysis**, 2011, disponível em <https://ec.europa.eu/jrc/en/samo/simlab>.

SOBOL, I.M. Sensitivity estimates for nonlinear mathematical models. **Mathematical Modelling and Computational Experiment**, v.1, p. 407-414, 1993.

STEIN, M. Large sample properties of simulations using Latin hypercube sampling. **Technometrics**, v. 29, p. 143-151, 1987.

STRUCK, C.; HENSEN, J.; KOTEK, P. On the application of uncertainty and sensitivity analysis with abstract building performance simulation tools. **Journal of Buildings Physics**, v. 33, p.5-27, 2009.

SUN, Y., GU, L., WY, C.F.J., AUGENBROE, G. Exploring HVAC system sizing under uncertainty. **Energy and Buildings**, v. 81, p. 243-252, 2014.

TIAN.W.;DE WILDE, P. Uncertainty an sensitivity analysis of building performance using probabilistic climate projections: A UK case study. **Automation in Construction**, v. 20, p.1096-1109, 2011.

TIAN, W. A review of sensitivity analysis methods in building energy analysis. **Renewable and Sustainable Energy Reviews**, v.20, p. 41-419, 2013.

TRCKA, M., HENSEN, J.L.M. Overview of HVAC system simulation. **Automation in Construction**, v. 19, p. 93-99, 2010.

TSO, G.K.F., YAU, K.K.W. Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks. **Energy**, v. 32, p. 1761-1768, 2007.

U.S. DOE. **EnergyPlus Version 8.5 Documentaion: Input Output Reference**, 2016.

VENABLES, W.N.; RIPLEY, B.D. **Modern applied statistics with S**. New York: Springer-Verlag, 2002.

VERSAGE, R.S. **Metamodelo para avaliação do desempenho energético de edificações comerciais condicionadas artificialmente**. 2015. 131 f. Tese (Doutorado em Engenharia Civil)—Programa de Pós Graduação em Engenharia Civil, Universidade Federal de Santa Catarina, Florianópolis, 2015.

WANG, H., ZHAI, Z.J. Advances in building simulation and computational techniques: A review between 1987 and 2014. **Energy and Buildings**, v.128, p. 319-335, 2016.

WANG, S.K. **Handbook of air conditioning and refrigeration**. Segunda edição. McGraw-Hill, New York, NY, USA, 2001.

WANG, S., XU, X. Simplified building model for transient thermal performance estimation using GA-based parameter identification. **International Journal of Thermal Sciences**, v. 45, p. 419-432, 2006.

WEI, Y., ZHAN, X., SHI, Y., XIA, L., PAN, S., WU, J., HAN, M., ZHAO, X. A review of data-driven approaches for prediction and classification of buildings energy consumption. **Renewable and Sustainable Energy Reviews**, p. 1027-1047, 2018.

WESTPHAL, F.S., LAMBERTS, R. Regression analysis of electric energy consumption of commercial buildings in Brazil. **Proceedings of Building Simulaton**, p. 1543-1550, 2007.

WESTPHAL, F. S. Análise de Incertezas e de Sensibilidade Aplicadas à Simulação de Desempenho Energético de Edificações Comerciais. (Tese de doutorado). Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2007. 147 p.

XU, X. TAYLOR, J.E., PISELLO, A.L., CULLIGAN, P.J. The impact of place-based affiliation networks on energy conservation: An holistic model that integrates the influence of buildings, residents and the neighborhood context. **Energy and Buildings**, v.55, p. 637-646, 2012.

YAN, L. **Energy consumption analyses of frequently –used HVAC system types in high performance office buildings**. 2014. 86 f. Thesis (Master fo Science)—Architectural Engineering Program, The Pennsylvania State University.

YOKOYAMA, R., WAKUI, T., SATAKE, R. Prediction of energy demands using neural network with model identification by global optimization. **Energy Conversion and Management**, v.50, p. 319-327, 2009.

YU, F.W., CHAN, K.T. Energy signatures for assessing the energy performance of chillers. **Energy and Buildings**, v.37, p. 739-746, 2005.

YU, F.W., CHAN, K.T. An alternative approach for the performance rating of air-cooled chillers used in air-conditioned buildings. **Building and Environment**, v.41, p. 1723-1730, 2006.

ZHAO, H., MAGOULÈS, F. A review on the prediction of building energy consumption. **Renewable and Sustainable Energy Reviews**, v.16, p. 3586-3592, 2012.

ZHOU, S., ZHU, N. Multiple regression models for energy consumption of office buildings in different climates in China. **Frontiers in Energy**, v.7, p. 103-110, 2013.

ANEXO A – CHILLERS UTILIZADOS PARA CRIAR A BASE DE DADOS

O modelo empregado nas simulações realizadas nesta tese é um dos modelos de modelagem de *chiller* elétrico, presente no Energyplus, baseado na temperatura de entrada no condensador (Chiller:Electric:EIR). Este modelo simula o desempenho térmico do *chiller* e o consumo de energia do(s) compressor(es) e dos ventiladores (no caso dos *chillers* a ar). O modelo usa informações de desempenho em condições de referência, e três curvas que permitem ajustar a capacidade de resfriamento e a eficiência em condições diferentes das condições de referência. As três curvas são:

- Curva da capacidade de refrigeração em função da temperatura;
- Curva do EIR (*Energy Input to Cooling Output Ratio*) em função da temperatura;
- Curva do EIR em função da relação de carga parcial (PLR – *Part Load Ratio*)

A curva da capacidade em função da temperatura (Equação A1) é uma curva biquadrática com duas variáveis independentes: a temperatura de saída da água gelada (T_{as}) e a temperatura de entrada do fluido no condensador (T_{fe}). O resultado desta equação é multiplicado pela capacidade de refrigeração de referência do *chiller*, especificada para as condições de plena carga em condições específicas de temperatura de operação. A curva é válida para uma dada faixa pré-determinada de temperaturas.

$$\begin{aligned} \text{ChillerCapFTemp} & \quad (A1) \\ & = a + b(T_{as}) + c(T_{as})^2 + d(T_{fe}) \\ & \quad + e(T_{fe})^2 + f(T_{as})(T_{fe}) \end{aligned}$$

Onde:

ChillerCapFTemp = Fator de correção da capacidade de refrigeração do *chiller*, igual a 1 nas condições de referência;

T_{as} = temperatura do setpoint de saída da água gelada (°C);

T_{fe} = temperatura do fluido na entrada do condensador do *chiller* (°C). Para *chiller* a água é a temperatura de entrada no *chiller* da água de condensação, e para *chiller* a ar é a temperatura de bulbo seco do ar externo na entrada do condensador.

A curva do EIR em função da temperatura (Equação A2) é uma curva biquadrática que parametriza a variação do EIR como uma função

da temperatura de saída da água gelada (T_{as}) e da temperatura de entrada do fluido no condensador (T_{fe}) do chiller. O EIR é o inverso do COP (Coeficiente de Performance). O resultado desta equação é multiplicado pelo EIR de referência do chiller, especificado para as condições de plena carga em condições específicas de temperatura de operação. A curva é válida para uma dada faixa pré-determinada de temperaturas.

$$\begin{aligned} \text{ChillerEIRFTemp} & & (A2) \\ &= a + b(T_{as}) + c(T_{as})^2 + d(T_{fe}) + e(T_{fe})^2 \\ &+ f(T_{as})(T_{fe}) \end{aligned}$$

Onde:

ChillerEIRFTemp = Fator de correção do EIR do chiller, igual a 1 nas condições de referência;

T_{as} = temperatura do setpoint de saída da água gelada ($^{\circ}\text{C}$);

T_{fe} = temperatura do fluido na entrada do condensador do chiller ($^{\circ}\text{C}$). Para chiller a água é a temperatura de entrada no chiller da água de condensação, e para chiller a ar é a temperatura de bulbo seco do ar externo na entrada do condensador.

A curva do EIR em função da relação de carga parcial (Equação A3) é uma curva quadrática que parametriza a variação da relação da potência de entrada do *chiller* em função da relação de carga parcial. A relação de carga parcial é a carga de resfriamento corrente dividida pela capacidade disponível de resfriamento do *chiller*. A curva é válida para uma dada faixa pré-determinada de PLR.

$$\text{ChillerEIRFPLR} = a + b(\text{PLR}) + c(\text{PLR})^2 \quad (A3)$$

Onde:

ChillerEIRFPLR = Fator de correção do EIR do chiller, igual a 1 nas condições de referência;

PLR = relação de carga parcial = (carga de resfriamento) / (capacidade disponível de refrigeração do chiller)

O resultado da Equação A3 é multiplicado pela curva da capacidade em função da temperatura (ChillerCapFTemp) e o pela curva do EIR em função da temperatura (ChillerEIRFTemp), para resultar na potência elétrica normalizada de entrada nas condições específicas de temperatura e carga parcial em que o chiller está operando, conforme equação A4.

$$(ChillerEIRFPLR)(ChillerCapFTemp)(ChillerEIRFTemp) \quad (A4)$$

$$= \frac{P_{chiller}}{P_{ref}}$$

Onde:

ChillerEIRFPLR = Fator de correção do EIR do *chiller*, igual a 1 nas condições de referência;

Pchiller = potência do *chiller* para um PLR específico;

Pref = potência elétrica do *chiller* nas condições de referência, que pode ser calculada multiplicando-se a capacidade de refrigeração de referência pelo EIR de referência.

Para cada passo de tempo da simulação, a capacidade disponível de refrigeração no *chiller* pode ser calculada pela Equação A5.

$$\dot{Q}_{disp} = \dot{Q}_{ref} (ChillerCapFTemp) \quad (A5)$$

Onde:

\dot{Q}_{ref} = capacidade do *chiller* nas condições de referência (W);

\dot{Q}_{disp} = capacidade disponível de refrigeração do *chiller* para as condições correntes de temperatura (W).

Portanto, para caracterizar os *chillers* é necessário informar as condições de referência e os coeficientes das três curvas de desempenho (Equações A1 a A3). Durante o processo de criação dos casos que foram simulados para a obtenção da base de dados, 25 *chillers* foram selecionados a partir dos *chillers* disponíveis na documentação do Energyplus (*Datasets*). A Tabela A1 apresenta as características destes *chillers*, a Tabela A2 as condições de referência, a Tabela A3 os coeficientes da curva *ChillerCapFTemp*, a Tabela A4 os coeficientes da curva *ChillerEIRFTemp*, a Tabela A5 as faixas de temperatura para as quais as duas curvas anteriores são válidas, e a Tabela A6 os coeficientes da curva *Chiller EIRFPLR*.

Tabela A1 - Características dos chillers utilizados para criar a base de dados.

Chiller	Fabricante/Modelo	COP a 100%	COP a 75%	COP a 50%	COP a 25%	IPLV
1	McQuay AGZ025BS	2,672	3,207	3,741	4,027	3,541
2	York YLAA0150SE	2,790	3,558	4,756	5,953	4,377
3	York YLAA0170SE	2,886	3,647	4,300	4,494	4,035
4	York YLAA0120SE	2,891	3,737	5,507	8,223	5,064
5	Carrier 30XA240	2,955	3,710	5,002	6,482	4,617
6	Trane CGAM130	3,054	4,140	5,456	6,047	4,950
7	Carrier 30XA325	3,078	3,799	4,752	5,524	4,428
8	Trane CGWD 207kW	4,004	4,870	5,768	5,724	5,368
9	Trane RTWA 383kW	4,174	4,859	5,526	5,254	5,199
10	McQuay PFH 932kW	4,908	5,572	6,327	5,886	5,943
11	Trane RTHB 1051kW	5,056	6,380	7,317	5,272	6,656
12	York YK 2412kW	5,251	5,283	5,164	3,699	5,039
13	York YS 781kW	5,413	6,820	7,929	5,747	7,176
14	Carrier 19FA 5651kW	5,509	6,124	6,429	5,135	6,136
15	York YT 1495kW	5,512	7,681	11,529	10,670	9,749
16	York YS 879kW	5,681	6,686	7,120	4,881	6,655
17	Carrier 19XL 1797kW	5,714	5,752	4,868	2,690	4,987
18	York YT 1023kW	5,783	6,907	7,711	5,678	7,110
19	Trane CVHF 4610kW	5,836	7,194	8,430	6,515	7,655
20	York YS 1758kW	5,857	6,892	7,127	4,834	6,740
21	Carrier 19XR 1407kW	5,968	6,944	7,472	6,313	7,096
22	Trane CVHE 1758kW	6,057	6,563	6,327	4,885	6,250
23	York YT 1758kW	6,328	7,337	8,043	6,232	7,512
24	Trane CVHF 2317kW	6,620	8,655	11,257	10,100	9,979
25	Trane CVHF 2043kW	7,005	8,284	9,007	6,753	8,413

Tabela A2 - Características de referência dos *chillers* utilizados para criar a base de dados.

Chiller	Tipo	Compressor	Capacidade de refrigeração (W)	COP	T _{as} (°C)	T _{fe} (°C)
1	a ar	Scroll	78.074	2,67	6,67	35,00
2	a ar	Scroll	161.300	2,81	6,67	35,00
3	a ar	Scroll	187.700	2,87	6,67	35,00
4	a ar	Scroll	133.200	2,93	6,67	35,00
5	a ar	Parafuso	801.600	3,00	6,67	35,00
6	a ar	Scroll	433.628	3,08	6,67	35,00
7	a ar	Parafuso	1.077.400	3,10	6,67	35,00
8	a água	Scroll	207.400	3,99	6,67	29,44
9	a água	Parafuso	383.300	4,17	6,67	29,44
10	a água	Centrífugo	931.900	5,09	4,44	26,11
11	a água	Parafuso	1.051.400	5,05	6,67	29,44
12	a água	Centrífugo	2.412.400	5,58	6,67	26,11
13	a água	Parafuso	780.700	5,42	6,67	29,44
14	a água	Centrífugo	5.651.300	5,50	6,67	29,44
15	a água	Centrífugo	1.494.500	7,51	7,22	23,89
16	a água	Parafuso	879.100	5,82	4,44	26,11
17	a água	Centrífugo	1.797.000	5,69	6,67	29,44
18	a água	Centrífugo	1.023.300	5,81	6,67	29,44
19	a água	Centrífugo	4.610.300	6,34	6,67	26,11
20	a água	Parafuso	1.758.300	5,84	6,67	29,44
21	a água	Centrífugo	1.406.600	6,04	6,67	29,44
22	a água	Centrífugo	1.758.300	5,96	6,67	29,44
23	a água	Centrífugo	1.758.300	6,28	6,67	29,44
24	a água	Centrífugo	2.317.400	6,33	5,56	29,44
25	a água	Centrífugo	2.043.100	9,08	4,44	18,33

Tabela A3 - Coeficientes da curva *ChillerCapFTemp* para os 25 *chillers* utilizados para criar a base de dados.

Chiller	a	b	c	d	e	f
1	1,01E+00	3,01E-02	1,04E-03	-4,14E-03	-2,08E-05	-3,72E-04
2	5,25E-01	3,90E-02	1,62E-04	3,05E-02	-6,20E-04	-3,85E-04
3	1,01E+00	3,63E-02	1,83E-04	-6,66E-04	-1,36E-04	-3,07E-04
4	-3,51E-01	3,89E-02	2,72E-03	8,75E-02	-1,38E-03	-1,60E-03
5	7,84E-01	4,97E-02	-7,70E-04	6,27E-03	-1,58E-04	-4,50E-04
6	1,04E+00	3,91E-02	1,88E-04	-3,15E-03	-9,85E-05	-3,39E-04
7	1,01E+00	3,17E-02	1,50E-04	-4,57E-03	-2,55E-05	-1,47E-04
8	9,44E-01	3,37E-02	9,76E-05	-3,22E-03	-4,92E-05	-1,78E-04
9	9,83E-01	3,68E-02	5,31E-05	-4,83E-03	-4,76E-05	-2,38E-04
10	1,18E+00	3,26E-02	-3,90E-03	4,58E-03	-1,03E-03	2,86E-03
11	9,48E-01	3,31E-02	-6,45E-05	-3,76E-03	-6,50E-05	2,52E-15
12	7,47E-01	8,07E-03	8,43E-05	1,93E-02	-7,51E-04	1,17E-03
13	1,00E+00	3,30E-02	3,74E-04	-5,93E-03	-2,60E-05	-2,17E-04
14	1,30E+00	1,79E-02	-2,52E-03	2,54E-03	-1,13E-03	3,00E-03
15	1,05E+00	-1,63E-01	1,15E-02	5,46E-02	-1,58E-03	1,63E-03
16	1,03E+00	3,36E-02	-2,74E-04	-3,79E-03	-1,55E-04	2,78E-04
17	9,08E-01	4,67E-02	-1,19E-03	-2,28E-03	-3,17E-05	-3,58E-04
18	2,57E-01	-1,57E-02	-3,04E-03	8,11E-02	-2,57E-03	4,25E-03
19	8,61E-01	-3,99E-03	-1,64E-03	8,88E-03	-3,93E-04	1,59E-03
20	8,13E-01	-1,43E-02	-1,62E-03	2,64E-02	-9,15E-04	1,70E-03
21	1,04E+00	2,64E-03	-1,47E-03	1,37E-02	-8,30E-04	1,57E-03
22	9,57E-02	-2,46E-02	-6,83E-03	7,12E-02	-2,05E-03	5,25E-03
23	7,08E-01	-2,01E-03	-2,60E-03	3,01E-02	-1,06E-03	2,05E-03
24	7,28E-01	1,02E-02	-6,28E-04	1,34E-02	-5,05E-04	1,53E-03
25	-1,34E+00	7,63E-03	-3,04E-03	1,99E-01	-4,53E-03	2,70E-03

Tabela A4 - Coeficientes da curva *ChillerEIRFTemp* para os 25 *chillers* utilizados para criar a base de dados.

Chiller	a	b	c	d	e	f
1	6,59E-01	-2,73E-03	-2,85E-04	1,16E-03	3,55E-04	-4,48E-04
2	2,38E-01	-4,50E-03	5,03E-04	2,14E-02	1,50E-04	-6,68E-04
3	7,16E-01	-3,16E-03	6,21E-04	-9,65E-03	6,46E-04	-7,73E-04
4	-1,66E-01	-3,77E-03	2,35E-03	4,66E-02	-1,40E-04	-1,53E-03
5	-3,08E-01	6,07E-02	1,00E-03	3,92E-02	-1,08E-06	-2,13E-03
6	5,44E-01	-1,08E-02	4,11E-04	4,22E-03	4,03E-04	-5,16E-04
7	1,27E-01	4,38E-02	-4,95E-04	1,94E-02	2,11E-04	-1,41E-03
8	7,27E-01	-1,19E-02	5,41E-04	1,88E-03	4,73E-04	-7,11E-04
9	6,23E-01	-8,70E-03	9,72E-04	5,18E-03	4,95E-04	-9,63E-04
10	6,05E-01	-1,09E-02	-1,51E-03	1,90E-02	-1,91E-04	9,01E-04
11	4,90E-01	-5,53E-03	1,21E-03	9,12E-03	5,92E-04	-1,47E-03
12	4,63E-01	-2,31E-02	1,17E-03	3,43E-02	-3,40E-04	-7,38E-05
13	4,48E-01	-1,05E-02	7,13E-04	1,16E-02	5,15E-04	-9,83E-04
14	7,85E-01	-1,65E-02	-3,29E-04	4,57E-03	1,96E-04	1,76E-04
15	7,11E-01	-2,09E-01	9,42E-03	8,49E-02	-1,26E-03	1,13E-03
16	5,60E-01	-1,09E-02	8,72E-04	1,01E-02	5,09E-04	-1,21E-03
17	1,08E+00	-4,32E-02	1,59E-03	1,66E-03	8,04E-05	5,68E-05
18	5,25E-01	-1,97E-02	3,44E-04	1,65E-02	2,01E-04	-3,19E-04
19	7,42E-01	-4,78E-02	-1,03E-03	1,42E-02	1,30E-04	9,17E-04
20	6,38E-01	6,30E-03	9,23E-04	-4,55E-03	8,26E-04	-1,56E-03
21	1,03E+00	-1,61E-02	-1,09E-03	-1,78E-02	7,96E-04	-9,59E-05
22	1,24E+00	-3,03E-02	3,45E-03	-2,74E-02	9,14E-04	-1,00E-03
23	5,61E-01	-1,38E-02	6,57E-05	1,32E-02	2,69E-04	-5,01E-04
24	3,50E-01	-2,30E-02	5,75E-04	1,90E-02	3,11E-04	-4,71E-04
25	6,07E-01	1,18E-02	2,10E-03	1,53E-02	6,76E-04	-2,63E-03

Tabela A5 - Faixas de temperatura para as quais as curvas *ChillerCapFTemp* e *ChillerEIRFTemp* são válidas.

Chiller	T_{as} mín.	T_{as} máx.	T_{fe} mín.	T_{fe} máx.
1	5,56	10,00	23,89	46,11
2	4,44	10,00	23,89	46,11
3	4,44	10,00	23,89	46,11
4	4,44	10,00	23,89	46,11
5	4,44	10,00	29,44	46,11
6	5,56	10,00	4,44	46,11
7	4,44	10,00	29,44	46,11
8	5,56	10,00	23,89	35,00
9	4,44	8,89	23,89	35,00
10	3,33	7,78	12,78	29,44
11	4,44	8,89	23,89	35,00
12	4,44	8,89	15,56	29,44
13	4,44	8,89	15,56	35,00
14	4,44	8,89	15,56	29,44
15	5,56	8,89	12,78	35,00
16	3,33	7,78	12,78	29,44
17	6,67	10,00	21,11	29,44
18	4,44	8,89	12,78	35,00
19	4,44	8,89	18,33	29,44
20	4,44	8,89	12,78	35,00
21	4,44	10,00	12,78	32,22
22	4,44	8,89	23,89	35,00
23	4,44	8,89	15,56	35,00
24	4,44	8,89	12,78	29,44
25	4,44	8,89	18,33	29,44

Tabela A6 - Coeficientes da curva *ChillerEIRFPLR* para os 25 *chillers* utilizados para criar a base de dados, e faixas de PLR para as quais a curva é válida.

Chiller	a	b	c	PLR mín.	PLR máx.	Unloading Ratio mín.
1	0,00E+00	1,00E+00	0,00E+00	0,15	1,00	0,10
2	0,00E+00	1,00E+00	0,00E+00	0,15	1,00	0,10
3	0,00E+00	1,00E+00	0,00E+00	0,15	1,00	0,10
4	0,00E+00	1,00E+00	0,00E+00	0,15	1,00	0,10
5	0,00E+00	1,00E+00	0,00E+00	0,15	1,00	0,10
6	4,93E-02	6,22E-01	3,28E-01			0,25
7	0,00E+00	1,00E+00	0,00E+00	0,15	1,00	0,10
8	4,15E-02	6,54E-01	3,04E-01	0,25	1,01	0,25
9	3,30E-02	9,11E-01	5,57E-02	0,25	1,01	0,25
10	6,82E-02	6,67E-01	2,65E-01	0,09	1,02	0,09
11	2,59E-01	2,15E-01	5,27E-01	0,20	1,01	0,20
12	2,47E-01	7,53E-01	8,64E-04	0,12	1,01	0,12
13	2,52E-01	2,76E-01	4,73E-01	0,09	1,01	0,09
14	1,63E-01	5,71E-01	2,66E-01	0,19	1,02	0,19
15	1,52E-01	-1,58E-01	1,01E+00	0,11	1,05	0,11
16	3,03E-01	3,22E-01	3,75E-01	0,10	1,02	0,10
17	5,93E-01	-2,66E-01	6,73E-01	0,39	1,01	0,39
18	2,37E-01	3,29E-01	4,34E-01	0,09	1,06	0,09
19	2,03E-01	2,92E-01	5,04E-01	0,20	1,02	0,20
20	3,15E-01	3,17E-01	3,71E-01	0,20	1,04	0,20
21	1,19E-01	6,72E-01	2,07E-01	0,20	1,04	0,20
22	1,87E-01	5,85E-01	2,29E-01	0,20	1,03	0,20
23	1,86E-01	5,48E-01	2,65E-01	0,20	1,06	0,20
24	9,86E-02	5,30E-01	3,71E-01	0,10	1,04	0,10
25	2,17E-01	4,39E-01	3,43E-01	0,28	1,04	0,28

Nesta tese, a temperatura de saída da água gelada foi mantida no valor de 6,7°C, a temperatura de entrada da água de condensação nos *chillers* a água foi mantida no valor de 29,4°C, enquanto que a temperatura de entrada do ar no condensador dos *chillers* a ar é função do clima da cidade simulada. Desta forma, a Figura A1 apresenta a variação do COP de cada *chiller* a ar em função da temperatura externa do ar, enquanto a Figura A2 apresenta a variação do COP em função da carga parcial (PLR) para os *chillers* a ar, e a Figura A3 a variação do COP em função da carga parcial (PLR) para os *chillers* a água.




Figura A1 - Variação do COP em função da temperatura externa do ar, para os *chillers* a ar utilizados na construção da base de dados.




Figura A2 - Variação do COP em função da carga parcial, para os *chillers* a ar utilizados na construção da base de dados.

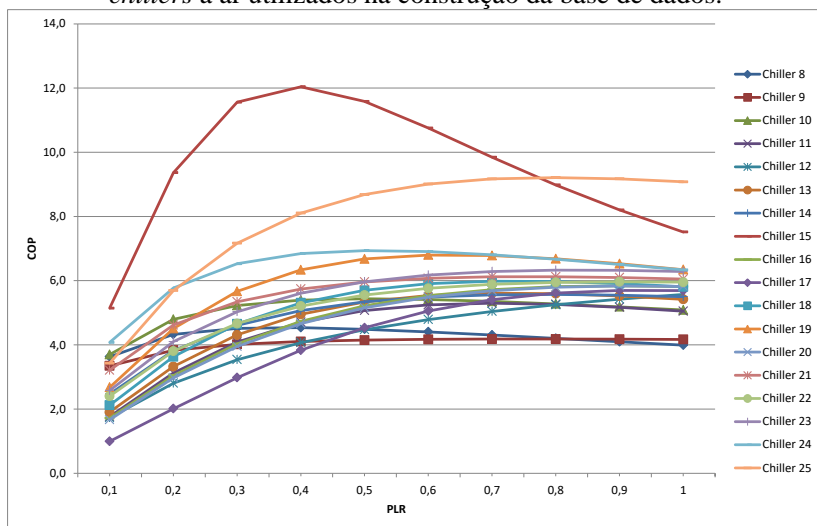


Figura A3 - Variação do COP em função da carga parcial, para os *chillers* a água utilizados na construção da base de dados.

ANEXO B - CHILLERS UTILIZADOS PARA CRIAR OS CASOS NÃO VISTOS

Conforme descrito no Anexo A, para caracterizar os *chillers* é necessário informar as condições de referência e os coeficientes das três curvas de desempenho (Equações A1 a A3). Durante o processo de criação dos casos que foram simulados para a obtenção dos chamados casos não vistos, sete *chillers* foram selecionados a partir dos *chillers* disponíveis na documentação do Energyplus (*Datasets*). A Tabela B1 apresenta as características destes chillers, a Tabela B2 as condições de referência, a Tabela B3 os coeficientes da curva *ChillerCapFTemp*, a Tabela B4 os coeficientes da curva *ChillerEIRFTemp*, a Tabela B5 as faixas de temperatura para as quais as duas curvas anteriores são válidas, e a Tabela B6 os coeficientes da curva *Chiller EIRFPLR*.

Tabela B1 - Características dos *chillers* utilizados para criar os casos não vistos.

Chiller	Fabricante/Modelo	COP a 100%	COP a 75%	COP a 50%	COP a 25%	IPLV
1	Carrier 30RB330	2,807	3,483	3,976	4,050	3,766
2	York YLAA0175HE	2,964	3,751	4,428	4,631	4,153
3	Trane CVHE 1329kW	5,199	5,273	5,169	4,617	5,147
4	Carrier 23XL 1062kW	5,515	6,767	7,890	5,666	7,128
5	York YK 4966kW	5,683	6,464	6,437	4,260	6,179
6	Carrier 19XL 1674kW	5,809	6,463	6,503	4,315	6,217
7	York YT 1055kW	5,915	7,092	7,919	5,680	7,283

Tabela B2 - Características de referência dos *chillers* utilizados para criar os casos não vistos.

Chiller	Tipo	Compressor	Capacidade de refrigeração (W)	COP	T _{as} (°C)	T _{fc} (°C)
1	a ar	Scroll	1.123.600	2,80	6,67	35,00
2	a ar	Scroll	190.000	2,96	6,67	35,00
3	a água	Centrífugo	1.329.300	5,38	6,11	29,44
4	a água	Parafuso	1.062.000	5,50	6,67	29,44
5	a água	Centrífugo	4.965.500	6,05	6,67	26,11
6	a água	Centrífugo	1.673.900	7,89	4,44	12,78
7	a água	Centrífugo	1.055.000	5,96	6,67	29,44

Tabela B3 - Coeficientes da curva *ChillerCapFTemp* para os sete *chillers* utilizados para criar os casos não vistos.

Chiller	a	b	c	d	e	f
1	8,91E-01	6,59E-02	-9,74E-04	-1,26E-03	-1,12E-04	-4,34E-04
2	1,02E+00	3,72E-02	1,81E-04	-1,10E-03	-1,33E-04	-3,24E-04
3	5,34E-01	1,02E-01	-3,98E-03	1,26E-02	-4,67E-04	-8,35E-05
4	1,03E+00	2,33E-02	-4,69E-03	-7,09E-03	-3,75E-04	2,84E-03
5	5,75E-01	-3,05E-02	-1,96E-04	3,31E-02	-9,17E-04	2,29E-03
6	2,93E-01	-4,41E-02	-1,29E-03	9,01E-02	-2,65E-03	3,39E-03
7	1,79E-01	-5,90E-02	-5,95E-04	9,30E-02	-2,84E-03	4,97E-03

Tabela B4 - Coeficientes da curva *ChillerEIRFTemp* para os sete *chillers* utilizados para criar os casos não vistos.

Chiller	a	b	c	d	e	f
1	0,918488	-0,02597	0,001729	-0,01355	0,000686	-0,00081
2	0,711845	-0,00224	0,000592	-0,00965	0,000651	-0,00078
3	8,07E-01	3,36E-02	-1,55E-03	-7,14E-03	5,06E-04	-7,55E-04
4	2,63E-01	-7,03E-03	-4,94E-04	2,52E-02	1,71E-04	-4,31E-04
5	8,23E-01	-8,13E-03	1,11E-03	-3,52E-03	6,13E-04	-9,17E-04
6	9,87E-01	-6,33E-02	3,50E-03	1,70E-02	2,57E-04	-4,23E-04
7	5,25E-01	-2,85E-02	8,03E-04	1,89E-02	1,15E-04	-9,34E-05

Tabela B5 - Faixas de temperatura para as quais as curvas *ChillerCapFTemp* e *ChillerEIRFTemp* são válidas.

Chiller	T _{as} mín.	T _{as} máx	T _{fe} mín	T _{fe} máx
1	4,44	15,56	29,44	48,89
2	4,44	10,00	23,89	46,11
3	6,11	10,00	21,11	29,44
4	6,67	10,00	21,11	29,44
5	4,44	8,89	15,56	29,44
6	4,44	8,89	12,78	29,44
7	4,44	8,89	12,78	35,00

Tabela B6 - Coeficientes da curva *ChillerEIRFPLR* para os sete *chillers* utilizados para criar os casos não vistos, e faixas de PLR para as quais a curva é válida.

Chiller	a	b	c	PLR mín.	PLR máx.	Unloading Ratio (mín.)
1	0,00E+00	1,00E+00	0,00E+00	0,15	1,00	0,10
2	0,00E+00	1,00E+00	0,00E+00	0,15	1,00	0,10
3	4,08E-02	1,17E+00	-2,21E-01	0,29	1,05	0,29
4	2,58E-01	3,42E-01	4,01E-01	0,20	1,01	0,20
5	3,42E-01	1,95E-01	4,64E-01	0,12	1,02	0,12
6	3,39E-01	2,62E-01	3,99E-01	0,32	1,02	0,32
7	2,62E-01	2,39E-01	4,99E-01	0,10	1,05	0,10

Nesta tese, a temperatura de saída da água gelada foi mantida no valor de 6,7°C, a temperatura de entrada da água de condensação nos *chillers* a água foi mantida no valor de 29,4°C, enquanto que a temperatura de entrada do ar no condensador dos *chillers* a ar é função do clima da cidade simulada. Desta forma, a Figura B1 apresenta a variação do COP de cada *chiller* a ar em função da temperatura externa do ar.




Figura B1 - Variação do COP em função da temperatura externa do ar, para os *chillers* a ar utilizados para gerar os casos não vistos.

A Figura B2 apresenta a variação do COP em função da carga parcial (PLR) para os chillers a ar, e a Figura B3 a variação do COP em função da carga parcial (PLR) para os chillers a água.




Figura B2 - Variação do COP em função da carga parcial, para os *chillers* a ar utilizados para gerar os casos não vistos.




Figura B3 - Variação do COP em função da carga parcial, para os *chillers* a água utilizados para gerar os casos não vistos.

ANEXO C – MÉTODO SOBOL

O método Sobol é uma técnica baseada em variância. O modelo é $y = f(x_1, x_2, \dots, x_k)$, onde x_1, x_2, \dots, x_k são os fatores independentes de entrada e y é a saída do modelo. A função de distribuição de probabilidade dos fatores de entrada é:

$$P(x_1, x_2, \dots, x_k) = \prod_{i=1}^k p_i(x_i) \quad (C1)$$

A média e a variância de y são:

$$E(y) = \int \int \dots \int f(x_1, x_2, \dots, x_k) \prod_{i=1}^k p_i(x_i) dx_i \quad (C2)$$

$$V(y) = \int \int \dots \int (f(x_1, x_2, \dots, x_k) - E(y))^2 \prod_{i=1}^k p_i(x_i) dx_i = \int \int \dots \int f^2(x_1, x_2, \dots, x_k) \prod_{i=1}^k p_i(x_i) dx_i - E^2(y) \quad (C3)$$

Se um dos fatores de entrada x_j é mantido fixo em um valor genérico \tilde{x}_j , a variância (condicional) resultante de y é:

$$V(y|x_j = \tilde{x}_j) = \int \int \dots \int (f(x_1, x_2, \dots, \tilde{x}_j, \dots, x_k) - E(y|x_j = \tilde{x}_j))^2 \prod_{\substack{i=1 \\ i \neq j}}^k p_i(x_i) dx_i = \int \int \dots \int (f^2(x_1, x_2, \dots, \tilde{x}_j, \dots, x_k) \prod_{\substack{i=1 \\ i \neq j}}^k p_i(x_i) dx_i - E^2(y|x_j = \tilde{x}_j)) \quad (C4)$$

Para fins da análise de sensibilidade é interesse eliminar a dependência sobre o valor \tilde{x}_j através da integração de $V(y|x_j = \tilde{x}_j)$ sobre a função de densidade de probabilidade de \tilde{x}_j , obtendo:

$$E(V(y|x_j)) = \int \int \dots \int f^2(x_1, x_2, \dots, x_j, \dots, x_k) \prod_{i=1}^k p_i(x_i) dx_i - \int E^2(y|x_j = \tilde{x}_j) p_j(\tilde{x}_j) d\tilde{x}_j \quad (C5)$$

A dependência de \tilde{x}_j é descartada do lado esquerdo da Equação C5, devido à integração. Subtraindo a Equação C5 da Equação C3 obtém-se:

$$V(y) - E(V(y|x_j)) = \int E^2(y|x_j = \tilde{x}_j) p_j(\tilde{x}_j) d\tilde{x}_j - E^2(y) \quad (C6)$$

Graças a uma identidade estatística, o lado esquerdo da Equação C6 é também igual à $V(E(y | x_j))$, e representa uma medida da sensibilidade $S_j = V(E(y | x_j)) / V(y)$ de y com relação ao fator x_j . Se dividirmos pela variância incondicional, obtemos o chamado índice de sensibilidade de primeira ordem. Os índices S_i 's são bem dimensionados em $[0,1]$. A Equação C6 é computacionalmente impraticável. Em um modelo de Monte Carlo, isso implica em um duplo loop $S_j = V(E(y | x_j)) / V(y)$: o interno para computar $E^2(y | x_j = \tilde{x}_j)$, e o externo para computar a integral sobre $d\tilde{x}_j$. Por esta razão, a integral na Equação C6 foi reescrita por Ishigami e Homma (1990) como:

$$\begin{aligned} & \int E^2(y|x_j = \tilde{x}_j) p_j(\tilde{x}_j) d\tilde{x}_j = \\ & \int \left\{ \int \dots \int f(x_1, x_2, \dots, \tilde{x}_j, \dots, x_k) \prod_{\substack{i=1 \\ i \neq j}}^k p_i(x_i) dx_i \right\}^2 p_j(\tilde{x}_j) d\tilde{x}_j = \\ & \int \int \dots \int f(x_1, x_2, \dots, \tilde{x}_j, \dots, x_k) f(x'_1, x'_2, \dots, \tilde{x}_j, \dots, x'_k) \prod_{\substack{i=1 \\ i \neq j}}^k (p_i(x_i) dx_i) \prod_{\substack{i=1 \\ i \neq j}}^k (p_i(x'_i) dx'_i) p_j(\tilde{x}_j) d\tilde{x}_j = \quad (C7) \\ & \int \int \dots \int f(x_1, x_2, \dots, x_j, \dots, x_k) f(x'_1, x'_2, \dots, x_j, \dots, x'_k) \prod_{\substack{i=1 \\ i \neq j}}^k (p_i(x_i) dx_i) \prod_{\substack{i=1 \\ i \neq j}}^k (p_i(x'_i) dx'_i) \end{aligned}$$

O expediente de usar a variável de integração adicional, nos permite perceber que a integral na Equação C7 é o valor de expectativa da função F de um conjunto $(2k - 1)$ de fatores:

$$\begin{aligned} & F(x_1, x_2, \dots, x_j, \dots, x_k, x'_1, x'_2, \dots, x'_{j-1}, x'_{j+1}, \dots, x'_k) = \\ & f(x_1, x_2, \dots, x_k) f(x'_1, x'_2, \dots, x'_{j-1}, x_j, x'_{j+1}, \dots, x'_k) \quad (C8) \end{aligned}$$

A integral da Equação C7 pode, portanto, ser calculada usando um único loop de Monte Carlo. O seguinte procedimento foi proposto por Sobol (1993) e revisado por Saltelli (2002).

Duas matrizes de amostra de entrada \mathbf{M}_1 e \mathbf{M}_2 são geradas:

$$\mathbf{M}_1 = \begin{matrix} x_{11} & x_{12} & \dots & x_{1k} \\ x_{21} & x_{22} & \dots & x_{2k} \\ \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & x_{nk} \end{matrix}, \quad \mathbf{M}_2 = \begin{matrix} x'_{11} & x'_{12} & \dots & x'_{1k} \\ x'_{21} & x'_{22} & \dots & x'_{2k} \\ \dots & \dots & \dots & \dots \\ x'_{n1} & x'_{n2} & \dots & x'_{nk} \end{matrix} \quad (\text{C9})$$

onde n é o tamanho da amostra utilizado para a estimativa de Monte Carlo. A fim de estimar a medida de sensibilidade para um fator genérico x_j , ou seja,

$$S_j = \frac{V(E(y|x_j))}{V(y)} = \frac{(U_j - E^2(y))}{V(y)} \quad (\text{C10})$$

$$U_j = \int E^2(y|x_j = \tilde{x}_j) p_j(\tilde{x}_j) d\tilde{x}_j$$

nós precisamos de uma estimativa para ambos, $E(y)$ e U_j . O primeiro pode ser obtido a partir de valores de y computados na amostra \mathbf{M}_1 ou na amostra \mathbf{M}_2 . U_j pode ser obtido dos valores de y computados na seguinte matriz \mathbf{N}_j :

$$\mathbf{N}_j = \begin{matrix} x'_{11} & x'_{12} & \dots & x_{1j} & \dots & x'_{1k} \\ x'_{21} & x'_{22} & \dots & x_{2j} & \dots & x'_{2k} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ x'_{n1} & x'_{n2} & \dots & x_{nj} & \dots & x'_{nk} \end{matrix} \quad (\text{C11})$$

ou seja, por:

$$\hat{U}_j = \frac{1}{n-1} \sum_{r=1}^n f(x_{r1}, x_{r2}, \dots, x_{rk}) f(x'_{r1}, x'_{r2}, \dots, x'_{r(j-1)}, x_{rj}, x'_{r(j+1)}, \dots, x'_{rk}) \quad (\text{C12})$$

Se pensarmos na matriz \mathbf{M}_1 como a matriz de amostra, e na matriz \mathbf{M}_2 como a matriz de reamostra, então \hat{U}_j é obtido a partir do produto entre valores de f calculados a partir dos valores da matriz de amostra e valores de f calculados de \mathbf{N}_j , ou seja, uma matriz onde todos os fatores são reamostrados exceto x_j . Desta forma, o custo computacional associado a um conjunto completo de índices de primeira ordem S_i é $n(k+1)$. Um conjunto n de avaliações de f é necessário para calcular

$E(y)$, e k conjuntos de n avaliações de f são necessários para o segundo termo do produto da Equação C12.

A configuração do problema de Sobol foi a identificação de um subconjunto de k fatores que pudesse explicar a maior parte da variância de y . Imagine que os fatores fossem particionados em um conjunto de testes $\mathbf{u} = (x_{i_1}, x_{i_2}, \dots, x_{i_m})$ e um conjunto restante $\mathbf{v} = (x_{l_1}, x_{l_2}, \dots, x_{l_{k-m}})$. Então, de acordo com Sobol, o efeito global do subconjunto \mathbf{u} na variância da saída pode ser estimado a partir de:

$$U_v = \iint \dots \int f(\mathbf{u}, \mathbf{v}) f(\mathbf{u}', \mathbf{v}) d\mathbf{u} d\mathbf{u}' d\mathbf{v} \quad (\text{C13})$$

$$V(E(y|\mathbf{v})) = U_v - E^2(y) \quad (\text{C14})$$

$$V(E(y|\mathbf{u})) + V(E(y|\mathbf{u}, \mathbf{v})) = V(y) - V(E(y|\mathbf{v})) \quad (\text{C15})$$

Na Equação C15, $V(E(y|\mathbf{u}))$, é o efeito de primeira ordem do conjunto \mathbf{u} , enquanto $V(E(y|\mathbf{u}, \mathbf{v}))$ é o termo de interação entre os conjuntos \mathbf{u} e \mathbf{v} . Se $V(y) \cong V(E(y|\mathbf{v}))$, então \mathbf{u} não é influente, e todos os fatores em \mathbf{u} podem ser fixados em uma análise subsequente do modelo. A Equação C13 mostra o mesmo expediente das variáveis de integração adicional já descritas. A estimativa de Monte Carlo de U_v é:

$$\hat{U}_v = \frac{1}{n-1} \sum_{r=1}^n f(x_{r_{i_1}}, x_{r_{i_2}}, \dots, x_{r_{i_m}}, x_{r_{l_1}}, x_{r_{l_2}}, \dots, x_{r_{l_{k-m}}}) f(x'_{r_{i_1}}, x'_{r_{i_2}}, \dots, x'_{r_{i_m}}, x_{r_{l_1}}, x_{r_{l_2}}, \dots, x_{r_{l_{k-m}}}) \quad (\text{C16})$$

ou seja, para estimar o efeito total do conjunto \mathbf{u} deve-se agora reamostrar as variáveis no conjunto \mathbf{u} . Pode-se facilmente verificar que a Equação C12 é um caso particular da Equação C16. As estimativas de erro para \hat{U}_j s são discutidos na referência original de Sobol.

A Equação C15 é um caso particular do método de decomposição geral da variância proposto por Sobol, pelo qual a variância incondicional pode ser decomposta como:

$$V(y) = \sum_i V_i + \sum_i \sum_{j>i} V_{ij} + \dots + V_{12\dots k} \quad (\text{C17})$$

onde $V_i = V(E(Y|x_i))$, $V_{ij} = V(E(Y|x_i, x_j)) - V_i - V_j$, e assim por diante. O desenvolvimento na Equação C17 contém k termos de primeira ordem V_i , $k(k-1)/2$ termos de segunda ordem V_{ij} e assim por diante, até o último termo de ordem k , para um total de $2^k -$

1 termos. Os termos V_{ij} são os termos de segunda ordem, análogos aos efeitos de segunda ordem nos livros texto de projeto experimental. Os termos V_{ij} capturam esta parte dos efeitos de x_i e x_j que não são descritos pelos termos de primeira ordem. A versão de Sobol da Equação C17 é baseada em uma decomposição da própria função f em termos de dimensionalidade crescente, ou seja,

$$f(x_1, x_2, \dots, x_k) = f_0 + \sum_i f_i + \sum_i \sum_{j>i} f_{ij} + \dots + f_{12\dots k} \quad (C18)$$

onde cada termo é função apenas dos fatores em seu índice, ou seja, $f_i = f_i(x_i)$, $f_{ij} = f_{ij}(x_i, x_j)$, e assim por diante. As decomposições (Equação C17 e Equação C18) são únicas, desde que os fatores de entrada sejam independentes e que os termos individuais $f_{i_1 i_2 \dots i_s}$ na Equação C18 sejam integráveis quadraticamente e tenham média zero sobre o domínio de existência.

Homma e Saltelli (1996) introduziram a nova estimativa U_{-j} :

$$\hat{U}_{-j} = \frac{1}{n-1} \sum_{r=1}^n f(x_{r1}, x_{r2}, \dots, x_{rj}, \dots, x_{rk}) f(x_{r1}, x_{r2}, \dots, x_{r(j-1)}, x'_{rj}, x_{r(j+1)}, \dots, x_{rk})$$

Como antes:

$$V(E(y | \mathbf{x}_{-j})) = \hat{U}_{-j} - \hat{E}^2(y) \quad (C19)$$

onde $V(E(y | \mathbf{x}_{-j}))$ é a contribuição total na variância de y devido ao não- x_j . Isto implica que a diferença $V(y) - V(E(y | \mathbf{x}_{-j}))$ é igual à soma de todos os termos na decomposição da variância (Equação C15) que incluem x_j . Para o caso com $k=3$:

$$S_1^T = \frac{V(y) - V(E(y | \mathbf{x}_{-1}))}{V(y)} = \frac{E(V(y | \mathbf{x}_{-1}))}{V(y)} = S_1 + S_{12} + S_{13} + S_{123} \quad (C20)$$

onde por exemplo $S_1 = V(E(y | x_1))/V(y)$, e expressões análogas podem ser escritas para S_2^T, S_3^T . Os termos S_j^T são chamados de termos de efeito total. Os efeitos totais são úteis para identificar fatores de entrada que não são influentes. Se o efeito total de um dado fator de entrada é insignificante, então este fator pode ter o seu valor fixado em qualquer valor dentro de sua faixa de incerteza (e portanto, a dimensionalidade do espaço da entrada pode ser reduzida).

Observe aqui que, quando o modelo é puramente aditivo, $\sum_{i=1}^k S_i = 1$, enquanto que, para um determinado fator x_j , uma diferença importante entre S_j^T e S_j sinaliza um importante papel das interações deste fator em y .

Uma análise de sensibilidade completa pode ser obtida estimando todos os termos na Equação C17, mas estes são tantos quanto $2^k - 1$. Este problema é chamado de maldição da dimensionalidade. O custo computacional para estimar todos os efeitos na Equação C17 é de fato tão grande quanto $n2^k$, onde novamente n é o tamanho da amostra usado para estimar o efeito individual (visto que $n(2^k - 1)$ seriam necessários para calcular todos os efeitos, e mais n para calcular $\hat{E}(y)$).

Por esta razão, costumeiramente é preferível computar o conjunto de todos os S_i mais o conjunto de todos os S_i^T , o que dá uma descrição bastante boa das sensibilidades do modelo. Com o método Sobol, isto implica em um custo computacional de $n(2k + 1)$ avaliações do modelo, ou seja, nk para os termos de primeira ordem, nk para os termos de efeito total, mais n para $\hat{E}(y)$.

Melhores estimativas para os índices de primeira ordem são obtidas se o termo $E^2(y)$ na Equação C10 é estimado como

$$\hat{E}^2 = \frac{1}{n} \sum_{r=1}^n f(x_{r1}, x_{r2}, \dots, x_{rk}) f(x'_{r1}, x'_{r2}, \dots, x'_{rk}) \quad (C21)$$

ao invés de

$$\hat{E}^2 = \left(\frac{1}{n} \sum_{r=1}^n f(x_{r1}, x_{r2}, \dots, x_{rk}) \right)^2 \quad (C22)$$

A Equação C21 é uma estimativa legítima da média quadrada da amostra dada a independência dos dois vetores amostra. É claro, a partir da Equação C10 e da Equação C12, que a estimativa de S_j vai mais naturalmente à zero para um fator não influente x_j quando a Equação C21 é utilizada, como pode ser visto a partir de:

$$\hat{U}_j - \hat{E}^2(y) = \frac{1}{n-1} \sum_{r=1}^n f(x_{r1}, x_{r2}, \dots, x_{rk}) f(x'_{r1}, x'_{r2}, \dots, x'_{r(j-1)}, x_{rj}, x'_{r(j+1)}, \dots, x'_{rk}) - \frac{1}{n} \sum_{r=1}^n f(x_{r1}, x_{r2}, \dots, x_{rk}) f(x'_{r1}, x'_{r2}, \dots, x'_{rk}) \quad (C23)$$

Por outro lado, o cálculo de todos os índices de efeito total é melhor realizado utilizando a Equação C22. $V(y)$ é calculado a partir de \mathbf{M}_1 para todos os índices. Como conclusão, a estratégia computacional padrão implementada até agora para calcular o conjunto completo de índices total e de primeira ordem implica em $n(2k + 2)$ avaliações do modelo, duas amostras sendo usada para estimar \hat{E}^2 .

ANEXO D – COEFICIENTES DA REDE RNA 29_sHIS

A rede neural artificial RNA 29_sHIS é composta por 14 neurônios de entrada, 29 neurônios na camada interna e 1 neurônio de saída. A Tabela D1 apresenta as variáveis que caracterizam os neurônios de entrada, bem como os valores do desvio padrão e da média destas variáveis na base de dados utilizada para o treinamento desta rede neural artificial. O neurônio de saída corresponde ao consumo anual do sistema de climatização por área de piso da edificação (transformado pela Equação 20 com $\lambda=0,70707$).

Tabela D1 – Neurônios de entrada da RNA 29_sHIS, e valores do desvio padrão e da média na base de dados.

Neurônio de entrada	Variável	desvio padrão na base de dados	valor médio na base de dados
1	Tipo de ventilação (0-VAC ou 1-VAV)	0,5000008	0,5005226
2	Pressão dos ventiladores (Pa)	199,9736	449,8422
3	Uso de ciclo economizador (0-ausente ou 1-presente)	0,4710755	0,3324029
4	Uso de recuperador de calor (0-ausente ou 1-presente)	0,4718916	0,3347147
5	Nível de renovação de ar (2,5 para o nível 1; 3,1 para o nível 2 ou 3,8 para o nível 3)	0,5312580	3,1333214
6	Pressão do bombeamento de água gelada (Pa)	199982,35	549897,53
7	Pressão do bombeamento de água de condensação (Pa)	170820,54	350035,46
8	Uso de circuito secundário de água gelada (0-ausente ou 1-presente)	0,4714345	0,3334153
9	Uso de vazão variável de água gelada (0-ausente ou 1-presente)	0,4712429	0,6671258
10	COP a 100% de carga do <i>chiller</i> nas condições AHRI 550/590	1,3592097	4,8396567
11	IPLV do <i>chiller</i> nas condições AHRI 550/590)	1,6375807	6,1865245
12	Número de <i>chillers</i> operando em paralelo (1, 2, 3 ou 4)	1,1184852	2,4995676
13	Carga térmica integrada anual de resfriamento por área de piso (transformada pela Equação 20 com $\lambda=0,74747$)	32,685919	72,194183
14	Indicador climático CEH	102322,30	178789,01

A Figura D1 apresenta uma representação gráfica de uma RNA com 8 neurônios de entrada (I1 à I8), 10 neurônios na camada interna (H1 à H10) e 1 neurônio de saída (O1). Nesta figura os pesos sinápticos estão ilustrados pelas ligações entre os neurônios, assim como os *bias* (B1 e B2). Portanto, uma rede neural artificial se caracteriza pelos valores dos pesos sinápticos e dos *bias*. A Tabela D2 apresenta os valores dos pesos sinápticos ($i_i \rightarrow h_j$, e $h_j \rightarrow o$) e *bias* ($b \rightarrow h_j$, e $b \rightarrow o$) obtidos para a rede RNA 29_sHIS.




Figura D1 – Representação de uma RNA com 8 neurônios de entrada, 10 neurônios na camada interna e 1 neurônio de saída (Fonte: <https://beckmw.wordpress.com/tag/nnet/>)

Tabela D2 - Coeficientes da rede neural artificial RNA 29_sHIS

b->h1	0,299402549	b->h2	0,382185	b->h3	36,88152	b->h4	-2,32729
i1->h1	0,071571615	i1->h2	0,065096	i1->h3	0,13281	i1->h4	-0,03392
i2->h1	0,050726785	i2->h2	-0,02208	i2->h3	0,173209	i2->h4	0,002065
i3->h1	-0,0116133	i3->h2	0,021312	i3->h3	0,118919	i3->h4	-0,01978
i4->h1	-0,03413546	i4->h2	-0,03511	i4->h3	0,062102	i4->h4	-0,02869
i5->h1	-0,00047183	i5->h2	-0,01013	i5->h3	0,005989	i5->h4	-0,01498
i6->h1	-0,01496591	i6->h2	-0,04595	i6->h3	-0,09654	i6->h4	-0,01375
i7->h1	0,1064309	i7->h2	-0,19529	i7->h3	0,018493	i7->h4	0,007311
i8->h1	0,003036383	i8->h2	-0,01408	i8->h3	0,019257	i8->h4	-0,07218
i9->h1	-0,0140772	i9->h2	-0,0009	i9->h3	-0,03132	i9->h4	0,051619
i10->h1	-0,51274748	i10->h2	0,922091	i10->h3	-13,1969	i10->h4	-0,12899
i11->h1	0,494184096	i11->h2	-0,29517	i11->h3	-2,80393	i11->h4	2,197289
i12->h1	-0,17866855	i12->h2	-0,12118	i12->h3	19,18234	i12->h4	0,083316
i13->h1	0,810531347	i13->h2	0,621801	i13->h3	-0,38912	i13->h4	0,03541
i14->h1	-0,05878157	i14->h2	-0,06021	i14->h3	-0,16315	i14->h4	-0,06746
b->h5	15,88055578	b->h6	-43,5902	b->h7	-7,48489	b->h8	-3,06781
i1->h5	-0,04056503	i1->h6	0,019587	i1->h7	1,697966	i1->h8	0,087429
i2->h5	-0,00645372	i2->h6	0,010299	i2->h7	-0,08356	i2->h8	0,258612
i3->h5	0,02878679	i3->h6	-0,01095	i3->h7	-0,22603	i3->h8	-0,08982
i4->h5	0,00061399	i4->h6	0,012246	i4->h7	0,365201	i4->h8	-0,01418
i5->h5	0,003521925	i5->h6	0,006218	i5->h7	-0,10929	i5->h8	-0,03882
i6->h5	-0,00859818	i6->h6	0,003458	i6->h7	0,030794	i6->h8	0,027222
i7->h5	-0,19622961	i7->h6	0,125935	i7->h7	0,12525	i7->h8	0,220316
i8->h5	-0,07054704	i8->h6	0,049375	i8->h7	-3,68015	i8->h8	0,23572
i9->h5	0,020015289	i9->h6	-0,00915	i9->h7	0,950245	i9->h8	-0,10595
i10->h5	13,83333409	i10->h6	-36,5841	i10->h7	-0,06325	i10->h8	0,070976
i11->h5	-3,20460568	i11->h6	7,171633	i11->h7	0,223012	i11->h8	0,346948
i12->h5	-0,04525213	i12->h6	0,053068	i12->h7	-4,39363	i12->h8	-0,17328
i13->h5	-0,16767837	i13->h6	0,040638	i13->h7	0,238129	i13->h8	0,787373
i14->h5	0,031564476	i14->h6	-0,01455	i14->h7	0,297973	i14->h8	0,034749

(continua)

Tabela D2 - Coeficientes da rede neural artificial RNA 29_sHIS
(continuação)

b->h9	-9,21359801	b->h10	-0,54125	b->h11	-3,01094
i1->h9	-0,0817607	i1->h10	0,650383	i1->h11	-0,66645
i2->h9	-0,14069117	i2->h10	-0,12111	i2->h11	-0,7536
i3->h9	0,222147953	i3->h10	0,056035	i3->h11	0,028259
i4->h9	0,016188325	i4->h10	0,076043	i4->h11	0,101801
i5->h9	-0,00130581	i5->h10	-0,01136	i5->h11	-0,0278
i6->h9	-0,01093442	i6->h10	-0,07343	i6->h11	-0,05208
i7->h9	0,234956984	i7->h10	-0,05613	i7->h11	-0,09393
i8->h9	-0,2344168	i8->h10	-0,02225	i8->h11	-0,15851
i9->h9	-0,13296212	i9->h10	-0,24076	i9->h11	0,154138
i10->h9	0,435367029	i10->h10	-0,08967	i10->h11	0,145427
i11->h9	-0,15612051	i11->h10	0,193209	i11->h11	-0,09099
i12->h9	-4,69757807	i12->h10	-1,13208	i12->h11	0,070518
i13->h9	1,604418201	i13->h10	-0,42084	i13->h11	0,476102
i14->h9	-1,20230013	i14->h10	-0,10887	i14->h11	-0,35487
b->h12	-0,86194824	b->h13	-4,23956	b->h14	-0,20068
i1->h12	-5,55662004	i1->h13	-0,12212	i1->h14	-0,07929
i2->h12	0,700063024	i2->h13	-0,06579	i2->h14	0,16734
i3->h12	-0,06344828	i3->h13	0,016995	i3->h14	-0,04024
i4->h12	7,711161004	i4->h13	-0,0769	i4->h14	-0,44704
i5->h12	-0,27713403	i5->h13	-0,03571	i5->h14	-0,01934
i6->h12	-0,16077614	i6->h13	0,478255	i6->h14	0,717601
i7->h12	-0,09351936	i7->h13	-0,03024	i7->h14	-0,62146
i8->h12	0,92209667	i8->h13	-3,05527	i8->h14	-9,14284
i9->h12	-0,62727799	i9->h13	0,473348	i9->h14	-0,56881
i10->h12	-1,13666393	i10->h13	-0,11852	i10->h14	-1,58513
i11->h12	0,31613245	i11->h13	0,132633	i11->h14	0,799826
i12->h12	2,538953151	i12->h13	-0,2308	i12->h14	5,418323
i13->h12	1,191834987	i13->h13	0,701693	i13->h14	-0,52154
i14->h12	1,262153342	i14->h13	-0,11072	i14->h14	-0,16179

(continua)

Tabela D2 - Coeficientes da rede neural artificial RNA 29_sHIS
(continuação)

b->h15	-31,7820449	b->h16	-2,62322	b->h17	1,72038
i1->h15	-2,66046174	i1->h16	0,114462	i1->h17	-0,18162
i2->h15	0,424147749	i2->h16	0,044833	i2->h17	0,090829
i3->h15	4,469607777	i3->h16	-0,02464	i3->h17	-0,04445
i4->h15	0,813605994	i4->h16	0,007624	i4->h17	0,051697
i5->h15	-0,00056583	i5->h16	-0,0043	i5->h17	0,001797
i6->h15	0,141842605	i6->h16	0,018123	i6->h17	0,388988
i7->h15	0,074826928	i7->h16	0,048573	i7->h17	0,093437
i8->h15	-0,00351529	i8->h16	0,061355	i8->h17	0,181346
i9->h15	-0,15836057	i9->h16	-0,01641	i9->h17	0,964768
i10->h15	-0,00902474	i10->h16	-0,89411	i10->h17	0,063099
i11->h15	-0,07873393	i11->h16	0,002014	i11->h17	0,050035
i12->h15	0,044829779	i12->h16	0,027807	i12->h17	-0,39339
i13->h15	2,2761639	i13->h16	0,472982	i13->h17	0,267607
i14->h15	-15,8014104	i14->h16	0,113617	i14->h17	0,014654
b->h18	-10,972871	b->h19	1,344188	b->h20	-7,48371
i1->h18	0,015989283	i1->h19	-3,42067	i1->h20	-0,77677
i2->h18	-0,04872343	i2->h19	-0,13084	i2->h20	0,303302
i3->h18	-0,08447509	i3->h19	-0,06175	i3->h20	1,441415
i4->h18	0,023628403	i4->h19	-0,50865	i4->h20	-2,17642
i5->h18	0,012615756	i5->h19	-0,03735	i5->h20	-0,05496
i6->h18	0,058357498	i6->h19	-0,42116	i6->h20	-0,0046
i7->h18	0,791744372	i7->h19	-0,53245	i7->h20	0,041575
i8->h18	-0,14353063	i8->h19	1,754822	i8->h20	0,169083
i9->h18	-0,04417689	i9->h19	6,559493	i9->h20	-0,16118
i10->h18	2,333225376	i10->h19	-0,63775	i10->h20	-0,00444
i11->h18	-0,63058519	i11->h19	-0,11616	i11->h20	0,037236
i12->h18	-7,95374245	i12->h19	0,543765	i12->h20	-0,13111
i13->h18	-0,10523811	i13->h19	-0,72841	i13->h20	0,573184
i14->h18	-0,0962608	i14->h19	-0,01377	i14->h20	-2,0104

(continua)

Tabela D2 - Coeficientes da rede neural artificial RNA 29_sHIS
(continuação)

b->h21	-6,95004852	b->h22	-2,83502	b->h23	-2,84174
i1->h21	-4,21775394	i1->h22	0,096939	i1->h23	0,236275
i2->h21	0,280523765	i2->h22	-0,37107	i2->h23	0,107564
i3->h21	-0,11358139	i3->h22	-0,04645	i3->h23	-13,892
i4->h21	0,669214642	i4->h22	-14,4179	i4->h23	-0,2062
i5->h21	-0,20208691	i5->h22	-0,29015	i5->h23	-0,2735
i6->h21	0,002173619	i6->h22	-0,05892	i6->h23	-0,14842
i7->h21	0,08354182	i7->h22	0,080665	i7->h23	0,282824
i8->h21	0,527708543	i8->h22	0,161937	i8->h23	0,4998
i9->h21	-0,36881147	i9->h22	0,142004	i9->h23	-0,28556
i10->h21	-0,29579608	i10->h22	-1,91336	i10->h23	-1,36115
i11->h21	-0,09356468	i11->h22	0,132802	i11->h23	1,765307
i12->h21	1,098331487	i12->h22	-0,21318	i12->h23	6,574159
i13->h21	0,910556176	i13->h22	-0,38535	i13->h23	0,165543
i14->h21	0,712996202	i14->h22	-11,6754	i14->h23	4,655158
b->h24	-3,76878226	b->h25	-2,44067	b->h26	6,875342
i1->h24	-0,08153127	i1->h25	-0,85118	i1->h26	-2,51213
i2->h24	0,149679949	i2->h25	0,245474	i2->h26	0,036818
i3->h24	0,119041173	i3->h25	-0,02164	i3->h26	0,261453
i4->h24	0,069542924	i4->h25	0,089502	i4->h26	-0,38904
i5->h24	0,001400514	i5->h25	0,039629	i5->h26	0,13922
i6->h24	0,066116272	i6->h25	-0,01883	i6->h26	0,019898
i7->h24	-0,00734148	i7->h25	-0,01444	i7->h26	0,013123
i8->h24	-0,02038428	i8->h25	0,03134	i8->h26	2,474426
i9->h24	0,016674846	i9->h25	0,059149	i9->h26	-0,77567
i10->h24	0,202105383	i10->h25	0,058981	i10->h26	0,412875
i11->h24	-0,5304782	i11->h25	-0,06085	i11->h26	-0,42219
i12->h24	0,065501442	i12->h25	0,10913	i12->h26	3,305369
i13->h24	-1,29099361	i13->h25	0,474896	i13->h26	-0,01457
i14->h24	0,007847737	i14->h25	-0,74962	i14->h26	0,016134

(continua)

Tabela D2 - Coeficientes da rede neural artificial RNA 29_sHIS
(conclusão)

b->h27	-15,7161154	b->h28	-0,18737	b->h29	10,45346
i1->h27	-0,13589141	i1->h28	-3,11512	i1->h29	-0,05101
i2->h27	-0,11657404	i2->h28	-0,09833	i2->h29	-0,02806
i3->h27	0,309626614	i3->h28	0,237177	i3->h29	-0,08379
i4->h27	-0,00994921	i4->h28	0,470527	i4->h29	-0,03619
i5->h27	-0,03669945	i5->h28	-0,07927	i5->h29	0,027089
i6->h27	-0,07855521	i6->h28	0,037089	i6->h29	-0,01468
i7->h27	0,149373205	i7->h28	-0,057	i7->h29	-0,0795
i8->h27	-0,13965258	i8->h28	7,887477	i8->h29	0,014995
i9->h27	-0,16149107	i9->h28	-7,7081	i9->h29	-0,03103
i10->h27	-0,16820627	i10->h28	-0,66029	i10->h29	1,83464
i11->h27	0,278077896	i11->h28	-0,05203	i11->h29	15,41089
i12->h27	-8,22609062	i12->h28	4,715882	i12->h29	0,3103
i13->h27	2,593338856	i13->h28	-0,73827	i13->h29	-0,00273
i14->h27	-1,72838827	i14->h28	0,268481	i14->h29	-0,04981
b->o	-37,3650192	h15->o	19,59610651		
h1->o	27,39515971	h16->o	44,01561105		
h2->o	14,46870486	h17->o	7,453151871		
h3->o	2,599625442	h18->o	5,787954		
h4->o	-8,64055163	h19->o	-2,609424		
h5->o	29,85988276	h20->o	17,99019625		
h6->o	18,10341044	h21->o	4,024856815		
h7->o	5,338459641	h22->o	0,501760532		
h8->o	22,31962898	h23->o	-0,82737681		
h9->o	18,87373086	h24->o	-28,370183		
h10->o	-7,33089735	h25->o	24,23339298		
h11->o	-16,5741437	h26->o	5,704602214		
h12->o	1,563116971	h27->o	-12,4061087		
h13->o	8,197095837	h28->o	1,431368576		
h14->o	2,39505816	h29->o	-5,11994552		

Para reproduzir a rede neural RNA 29_sHIS em uma planilha eletrônica (Excel, por exemplo) é necessário seguir os seguintes passos:

1. Escalonar e centralizar os valores dos dados de entrada, utilizando os valores de desvio padrão e média de cada variável, obtidos na base de dados empregada no treinamento da rede (Tabela D1), conforme Equação D1.

$$I_{iT} = \frac{I_i - \bar{I}_i}{\sigma_i} \quad (D1)$$

Onde:

I_{iT} = Valor transformado (escalonado e centralizado) da variável de entrada i ;

I_i = Valor da variável de entrada i ;

\bar{I}_i = Média da variável de entrada i na base de dados;

σ_i = Desvio padrão da variável de entrada i na base de dados.

Ressalta-se que a variável 13 (carga térmica) precisa passar pela transformação *box-cox* (Equação 20 com $\lambda=0,74747$), antes de ser escalonada e centralizada.

2. Aplicar os pesos sinápticos e bias que caracterizam a ligação entre a camada de entrada e a camada interna, conforme Equação D2.

$$x_j = \sum_{i=1}^N w_{ij} \cdot I_{iT} + b_j \quad (D2)$$

Onde:

x_j = Valor obtido para cada neurônio j da camada interna (j varia de 1 à 29 na RNA 29_sHIS);

N = Número de neurônios de entrada ($N=14$ na RNA 29_sHIS);

w_{ij} = peso sináptico entre o neurônio i de entrada e o neurônio j da camada interna (valores $i \rightarrow h_j$ da Tabela D2);

I_{iT} = Valor transformado (escalonado e centralizado) da variável de entrada i ;

b_j = *bias* aplicado ao neurônio j da camada interna (valores $b \rightarrow h_j$ da Tabela D2).

3. Aplicar a função ativação ao resultado do passo anterior. A função ativação sigmóide foi utilizada nesta tese, conforme Equação D3.

$$f_j = \frac{1}{1 + e^{-x_j}} \quad (D3)$$

Onde:

f_j = Resultado da função ativação para cada neurônio j da camada interna (j varia de 1 à 29 na RNA 29_sHIS);
 x_j = Valor obtido para cada neurônio j da camada interna com a aplicação dos pesos sinápticos e bias.

4. Calcular o valor da variável de saída, utilizando os pesos sinápticos e bias entre a camada interna e a camada de saída, conforme Equação D4.

$$O = \sum_{j=1}^N w_{jo} \cdot f_j + b_o \quad (D4)$$

Onde:

O = Resultado da variável de saída (neste caso, consumo do sistema de climatização por área de piso da edificação, transformada pela Equação 20 com $\lambda=0,70707$);

N = Número de neurônios na camada interna ($N=29$ na RNA 29_sHIS);

w_{jo} = peso sináptico entre o neurônio j da camada interna e o neurônio o de saída (valores $i_j \rightarrow o$ da Tabela D2);

f_j = Resultado da função ativação para cada neurônio j da camada interna (j varia de 1 à 29 na RNA 29_sHIS);

b_o = *bias* aplicado ao neurônio o da camada de saída (valor $b \rightarrow o$ da Tabela D2).