



UNIVERSIDADE FEDERAL DE MATO GROSSO

INSTITUTO DE FÍSICA

PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA AMBIENTAL

**Proposta de Rede Neural Artificial para Previsão do
Conforto Térmico Utilizando o ASHRAE *Global Thermal
Comfort DataBase II***

FERNANDA MARCIELLI SANTOS

Cuiabá, MT

Julho de 2022.

UNIVERSIDADE FEDERAL DE MATO GROSSO

INSTITUTO DE FÍSICA

PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA AMBIENTAL

**Proposta de Rede Neural Artificial para Previsão do
Conforto Térmico Utilizando o ASHRAE *Global
Thermal Comfort DataBase II***

FERNANDA MARCIELLI SANTOS

Tese apresentada ao Programa de Pós-Graduação em Física Ambiental da Universidade Federal de Mato Grosso, como parte dos requisitos para obtenção do título de Doutora em Física Ambiental, na área de Análise e Modelagem Microclimática de Sistemas Urbanos.

ORIENTADOR: PROF. DR. CARLO RALPH DE MUSIS

Cuiabá, MT

Julho de 2022.

Dados Internacionais de Catalogação na Fonte.

S237p Santos, Fernanda Marcielli.
Proposta de Rede Neural Artificial para Previsão do Conforto Térmico Utilizando o ASHRAE Global Thermal Comfort DataBase II / Fernanda Marcielli Santos. -- 2022
135 f. ; 30 cm.

Orientador: Carlo Ralph de Musis.
Tese (doutorado) - Universidade Federal de Mato Grosso, Instituto de Física, Programa de Pós-Graduação em Física Ambiental, Cuiabá, 2022.
Inclui bibliografia.

1. sensação térmica. 2. aprendizagem de máquina. 3. climatologia urbana. 4. redes neurais artificiais. 5. modelo preditivo. I. Título.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

Permitida a reprodução parcial ou total, desde que citada a fonte.



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE MATO GROSSO
PRÓ-REITORIA DE ENSINO DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM FÍSICA AMBIENTAL

FOLHA DE APROVAÇÃO

TÍTULO: PROPOSTA DE REDE NEURAL ARTIFICIAL PARA PREVISÃO DO CONFORTO TÉRMICO UTILIZANDO O ASHRAE CONFORT DATABASE II

AUTORA: DOUTORANDA: **FERNANDA MARCIELLI SANTOS**

Tese defendida e aprovada em **28** de **julho** de **2022**.

COMPOSIÇÃO DA BANCA EXAMINADORA

1. **Prof. Dr. CARLO RALPH DE MUSIS** (Presidente Banca / orientador)
INSTITUIÇÃO: Universidade de Cuiabá
2. **Prof. Dr. RAPHAEL DE SOUZA ROSA GOMES** (Membro Interno)
INSTITUIÇÃO: Universidade Federal de Mato Grosso
3. **Prof. Dr. JOSIEL MAIMONE DE FIGUEIREDO** (Membro Interno)
INSTITUIÇÃO: Universidade Federal de Mato Grosso
4. **Profa. Dra. JULIANA QUEIROZ BORGES DE MAGALHÃES CHEGURY** (Membro Externo)
INSTITUIÇÃO: Universidade Federal de Mato Grosso - Campus de Várzea Grande
5. **Profa. Dra. LAIS BRAGA CANEPPELE** (Membro Externo)
INSTITUIÇÃO: Universidade Estadual de Mato Grosso
6. **Prof. Dr. JONATHAN WILLIAN ZANGESKI NOVAIS** (Suplente)
INSTITUIÇÃO: Universidade de Cuiabá

Cuiabá, 28/07/2022.



Documento assinado eletronicamente por **SERGIO ROBERTO DE PAULO, Coordenador(a) de Programas de Pós-Graduação em Física Ambiental - IF/UFMT**, em 03/08/2022, às 12:53, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **CARLO RALPH DE MUSIS, Usuário Externo**, em 03/08/2022, às 14:41, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **JOSIEL MAIMONE DE FIGUEIREDO, Docente da Universidade Federal de Mato Grosso**, em 03/08/2022, às 15:16, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **RAPHAEL DE SOUZA ROSA GOMES, Docente da Universidade Federal de Mato Grosso**, em 03/08/2022, às 17:22, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Juliana Queiroz Borges de Magalhães Chegury, Usuário Externo**, em 03/08/2022, às 18:10, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Jonathan Willian Zangeski Novais, Usuário Externo**, em 03/08/2022, às 19:52, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Laís Braga Caneppele, Usuário Externo**, em 16/08/2022, às 15:49, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufmt.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **4976813** e o código CRC **1D79558B**.

DEDICATÓRIA

À minha família e ao meu orientador.

AGRADECIMENTOS

A Deus, fonte de todo o amor, inspiração e fé. Para poder pesquisar e escrever este trabalho tive que vencer muitos desafios e acreditar bastante em sua ajuda.

À mãe Solange e aos meus pais-avós, Cleusa e Antônio, que são meus alicerces e bússolas da minha vida, recebendo-me sempre de braços abertos, acreditando no meu potencial e dando-me todo amor para que eu pudesse crescer e ser quem sou. Pelos seus exemplos e ensinamentos de vida e por todo estímulo para eu estudar e conseguir o título de “doutora”, minha eterna gratidão. E também aos meus irmãos, tios, primos, sobrinhos, sogros e cunhados que são a família material e espiritual que Deus me confiou.

Ao meu esposo André, por ser meu companheiro de vida, dar-me força, coragem e incentivo, e ter topado uma mudança tão grande para que eu pudesse realizar um sonho. Às minhas filhas, Juliana e Mariana, por serem as fontes sagradas de amor e luz que fazem a vida valer a pena e às quais dedico minhas conquistas. Saibam que tudo na vida requer esforço e disciplina e que sem Deus ficamos perdidos, sem um rumo. Espero que meu exemplo possa despertar em vocês desejos de grandes sonhos e realizações enormes de tudo o que planejam.

Ao meu orientador, prof. Dr. Carlo Ralph de Musis por tudo que me ensinou ao longo do curso, pela sua amizade e por todas as contribuições para desenvolver um tema tão novo para mim. Meus sinceros agradecimentos e minha admiração pela pessoa que é e por poder contar com sua excelente orientação e paciência em todos os momentos.

Ao Programa de Pós-Graduação em Física Ambiental da Universidade Federal de Mato Grosso, aqui representado pelos professores, colaboradores, secretários e discentes que prezam pela qualidade do ensino e realizam suas tarefas com maestria, visando o desenvolvimento de cada aluno, especialmente *in memoriam* do brilhante prof. Dr. José de Souza Nogueira (Prof. Paraná). À banca examinadora pelas importantes contribuições dadas a este trabalho.

A todos os amigos e colegas que me ajudaram de alguma forma.

À CAPES pela bolsa de estudos.

À Casa Civil do Governo do Estado de Mato Grosso, que disponibilizou o servidor para rodar a Rede Neural Artificial (RNA).

“Conhecer os outros é inteligência,
conhecer-se a si próprio é a verdadeira sabedoria.
Controlar os outros é força,
controlar-se a si próprio é o verdadeiro poder.”

Lao-Tsé-Tung

SUMÁRIO

LISTA DE FIGURAS	12
LISTA DE TABELAS	13
RESUMO	14
ABSTRACT	15
1. INTRODUÇÃO	16
1.1. JUSTIFICATIVA	18
2. REVISÃO BIBLIOGRÁFICA	20
2.1. METEOROLOGIA E CLIMATOLOGIA	20
2.1.1. CLASSIFICAÇÃO CLIMÁTICA	23
2.2. CLIMATOLOGIA URBANA	27
2.2.1. HISTÓRICO SOBRE CLIMATOLOGIA URBANA	27
2.2.2. CLIMATOLOGIA URBANA E SUAS INFLUÊNCIAS	33
2.3. CONFORTO TÉRMICO	39
2.3.1. CONCEITO DE CONFORTO TÉRMICO	39
2.3.2. MÉTRICAS DE CONFORTO TÉRMICO	44
2.4. REDES NEURAS ARTIFICIAIS (RNAs)	55
2.4.1. INTRODUÇÃO À INTELIGÊNCIA ARTIFICIAL	56
2.4.2. FUNCIONAMENTO REDES NEURAS ARTIFICIAIS (RNAs)	64
2.4.3. AJUSTE DE HIPERPARÂMETROS	74

2.4.4. VERIFICANDO O DESEMPENHO DA RNA	78
2.4.4.1. CRITÉRIO AVALIAÇÃO DE DESEMPENHO	81
2.4.4.2. VALIDAÇÃO	82
2.5. <i>OVERFITTING</i> E <i>UNDERFITTING</i>	83
2.6. APLICAÇÕES DAS RNAs	84
3. MATERIAIS E MÉTODOS	95
3.1. LINGUAGEM DE PROGRAMAÇÃO	95
3.2. BANCO DE DADOS ASHRAE	97
3.2.1. COMPOSIÇÃO DO BANCO DE DADOS ASHRAE	98
3.2.2. ALIMENTAÇÃO DA RNA COM BANCO DE DADOS	102
3.3. PARÂMETROS E HIPERPARÂMETROS DA REDE <i>FEED-FORWARD</i> (FF)	103
3.4. DESENVOLVIMENTO DO MODELO DE RNA-FF	106
4. RESULTADOS E DISCUSSÕES	111
5. CONCLUSÕES	122
6. REFERÊNCIAS BIBLIOGRÁFICAS	124

LISTA DE FIGURAS

1- Escalas climáticas horizontais e camadas verticais em zona urbana. mesoescala; b) escala local; c) microescala.	38
2- Mecanismos de controle de temperatura do corpo.	42
3- Porcentagem Pessoas Insatisfeitas (PPD) em função do Voto Médio Estimado (PMV).	49
4- Neurônios pré e pós-sinápticos, demonstrando a região de acoplamento onde ocorre a sinapse. É possível verificar o sentido de propagação do sinal elétrico entre os neurônios pré e pós-sinápticos.	65
5- Neurônio Artificial de McCulloch e Pitts.	67
6- Diagrama de uma Rede Neural Artificial (RNA) com camada simples.	69
7- Diagrama Rede Neural Artificial (RNA) com múltiplas camadas (DFF).	72
8- Exemplo de overfitting e underfitting.	84
9- Fluxograma do Modelo de RNA.	107
10- Matriz de dispersão com gráficos de dispersão e funções de densidade de distribuição das variáveis.	112
11- a) Derivada do erro MAE em função do número de neurônios; b) erro MAE em função do número de neurônios.	114
12- <i>Hexaplot</i> do número de neurônios em função do erro MAE.	116
13- Evolução da função de perda em 65 épocas.	117
14- Sensação térmica estimada <i>versus</i> observada.	118

LISTA DE TABELAS

1- Valor da regressão (b)	118
2- Análise de variância ANOVA (a)	119
3- Coeficientes (a)	120
4- Estatística de resíduos (a)	121

RESUMO

SANTOS, F. M. Proposta de Rede Neural Artificial para Previsão do Conforto Térmico Utilizando o ASHRAE *Global Thermal Comfort DataBase II*. Cuiabá, 2022, 89f. Tese (Doutorado em Física Ambiental na Área de Concentração: Análise e Modelagem Microclimática de Sistemas Urbanos), Instituto de Física, Universidade Federal de Mato Grosso.

Este trabalho tem como objetivo desenvolver uma Rede Neural Artificial (RNA) para prever um modelo de conforto térmico. Foi usado o banco de dados da ASHRAE que reúne dados climatológicos de trabalhos científicos mundiais, compilados de 1985 a 2018. A RNA foi treinada, usando os parâmetros do banco de dados e sua arquitetura foi do tipo *Feed-Forward* (FF) com três camadas triangulares, otimizador *NAdam* com taxa de aprendizado de 0,01, função de ativação *ReLU* nas três camadas, porcentagem de treinamento/teste de 70:30, *batch size* de 512 e *epochs* de 1500. Para a entrada usou-se: índice de resistência térmica das vestimentas (clo), taxa de metabolismo individual (met), temperatura do ar (°C), umidade relativa do ar (%), velocidade do ar (m/s) e temperatura externa mensal do ar (°C); e um parâmetro de saída: sensação térmica. A RNA treinada apresentou um erro de 13,7%, com pelo menos 100 neurônios. A estimativa da sensação térmica foi avaliada pela análise de variância (ANOVA) e apresentou um bom ajuste. O coeficiente de correlação (R) teve o valor próximo de 1, indicando um alto grau de correlação, enquanto o coeficiente de determinação foi significativo para o modelo, considerando o baixo erro padrão de estimativa. O valor do teste F maior que 1 demonstra melhoria devido ao ajuste do modelo de regressão ser muito maior que sua variação no interior do modelo. A partir da calibração e validação da RNA foi possível verificar uma boa acurácia do modelo. Os resultados alcançados mostraram que a RNA conseguiu realizar previsões assertivas sobre a sensação térmica, o que leva a concluir que o modelo apresentou capacidade de aprendizagem e generalização dos resultados satisfatórios.

Palavras-chaves: sensação térmica; aprendizagem de máquina; climatologia urbana.

ABSTRACT

SANTOS, F. M. Artificial Neural Network Proposal for Thermal Sensation Prediction Using ASHRAE *Global Thermal Comfort DataBase II*. Cuiabá, 2022, 89f. Thesis (Doctorate degree in Environmental Physics in the Concentration area: Analysis Microclimatic Modeling of Urban Systems), Institute of Physics, Federal University of Mato Grosso.

This work aims to develop an Artificial Neural Network (ANN) to predict a thermal comfort model. The ASHRAE database was used, which gathers climatological data from worldwide scientific works, compiled from 1985 to 2018. The ANN was trained using the parameters of the database and its architecture was of the Feed-Forward (FF), type with three triangular layers, NAdam optimizer with a learning rate of 0.01, ReLu activation function in the three layers, training/test percentage of 70:30, batch size of 512 and epochs of 1500. For the input we used: thermal resistance index clothing (clo), individual metabolism rate (met), air temperature (°C), relative air humidity (%), air velocity (m/s) and monthly external air temperature (°C); and an output parameter: thermal sensation. The trained ANN presented an error of 13.7%, with at least 100 neurons. The thermal sensation estimate was evaluated by analysis of variance (ANOVA) and showed a good fit. The correlation coefficient (R) was close to 1, indicating a high degree of correlation, while the determination coefficient was significant for the model, considering the low standard error of estimation. The F test value greater than 1 demonstrates improvement due to the regression model fit being much greater than its variation within the model. From the calibration and validation of the ANN, it was possible to verify a good accuracy of the model. The results showed that the ANN was able to make assertive predictions about the thermal sensation, which leads to the conclusion that the model showed a capacity for learning and generalization of satisfactory results.

Keywords: Thermal sensation; machine learning; urban climatology.

1. INTRODUÇÃO

Este capítulo faz uma breve introdução sobre a problemática, a justificativa e a motivação que levou a desenvolver esta pesquisa.

O conforto térmico é representado pela satisfação de bem-estar individual relacionada às condições térmicas quando o corpo está em equilíbrio térmico em relação ao ambiente construído. Representa um estado atingido quando o corpo não sente incômodos relacionados ao calor e ao frio e não precisa recorrer a mecanismos de termorregulação corporal.

Para a análise do conforto térmico no ambiente construído é necessário coletar informações climáticas do local e compreender o aspecto físico, psicológico e fisiológico dos indivíduos no momento da avaliação destas percepções.

A constituição física do edifício e o desenvolvimento de tecnologias dos materiais para isolamento ou armazenamento térmico e controle de temperatura e umidade, tem impacto profundo na melhoria do ambiente construído em termos de eficiência energética e conforto térmico. Com a utilização de materiais avançados e tecnologias passivas em edifícios é possível reduzir a demanda de energia e melhorar o desempenho térmico das edificações.

A importância do processo de armazenamento de calor, durante o dia, nas edificações e seu retorno para a atmosfera durante a noite, além do conhecimento das propriedades físicas dos materiais torna interessante o conhecimento de Física Ambiental. O uso de estratégias para mitigar os problemas oriundos da má utilização dos materiais, buscando soluções que proporcionem conforto térmico individual, pode ser proporcionado através deste conhecimento multidisciplinar.

A par disso, em todas as partes do mundo existem pesquisas científicas relacionadas à análise e modelagem microclimática de sistemas urbanos. Contando com o trabalho de uma equipe que reuniu dados de diversas regiões do globo terrestre, uma coletânea dessas pesquisas foi agrupada em um banco de dados chamado ASHRAE

Global Thermal Comfort II. Para respaldar estas investigações, os pesquisadores analisaram indicadores de conforto térmico medindo variáveis dentro ou fora das construções para verificar o nível de conforto ou desconforto térmico percebidos pelas pessoas.

Observa-se que algumas ferramentas de Inteligência Artificial (IA), usando aprendizagem de máquina (*machine learning*), como aprendizagem profunda (*deep learning*) ou o método de Rede Neural Artificial – RNA (em inglês, ANNs: *Artificial Neural Networks*), é possível simular processos e prever modelos que apresentem boa capacidade de generalização aplicados a dados diferentes dos originais.

Atualmente a automatização das atividades e a “internet das coisas” vêm contribuindo para expandir a utilização de ferramentas computacionais em todas as áreas. Especificamente na área de Climatologia Urbana, o uso de abordagens de aprendizado de máquina pode ajudar a mapear respostas subjetivas ao ambiente físico e identificar tendências ocultas nas informações.

O uso de Inteligência Artificial vem crescendo com o aumento do poder computacional e com as plataformas *open source* que geram uma interação enorme com usuários de programas para treinar RNAs. Isso possibilita a construção de modelos que podem ser compartilhados na nuvem (*cloud*) com diversas pessoas em todo o mundo.

Sabendo disso, as métricas de conforto térmico (sensação térmica, preferência térmica, conforto térmico, aceitabilidade térmica, aceitabilidade do movimento do ar e preferência do movimento do ar) podem fornecer informação para determinar se o ambiente atende à expectativa térmica dos indivíduos.

A problemática geral se relaciona com a necessidade de criar modelos diferentes do modelo de Fanger, uma vez que ele não funciona para uma série de situações, conforme vários pesquisadores já mostraram. Assim, propõe-se criar um modelo preditivo que considere as variáveis climáticas e físicas individuais relacionadas ao conforto térmico das pessoas usando RNA.

1.1. JUSTIFICATIVA

Justifica-se a necessidade deste estudo pelo maior conhecimento das métricas de conforto térmico que podem ser alcançadas através do uso de Redes Neurais Artificiais (RNAs) para verificar a preferência térmica das pessoas em diferentes localidades em termos de variações apresentadas na aclimatação, usando um modelo de predição diferente do proposto por Fanger.

Embora o modelo de Fanger tenha inúmeras aplicações, há casos em que ele pode errar na predição, pois não considera a natureza fisiológica, estilo de vida, hábitos e adaptação do ser humano. Sendo assim, a técnica da RNA é uma alternativa que pode ser explorada para contribuir com a predição do conforto térmico.

Muitos estudos apontam as RNAs como uma técnica bem-sucedida por identificar padrões de semelhança não visíveis em amostras de dados. Com isso, a disponibilização de códigos que usam RNAs, para o estudo de conforto térmico, podem auxiliar pesquisadores que possuem vários dados e querem testar o código validado, fazendo os ajustes necessários de variação de parâmetros, o que facilita a análise.

Com um volume satisfatório de dados ambientais, surge o desafio de analisar os indicadores de conforto térmico que usam parâmetros diferentes. Esta análise pode ser feita com ferramentas computacionais de RNAs, que têm demonstrado eficiência em várias aplicações e pode facilitar os estudos climatológicos.

Aproveitando a reunião de trabalhos mundiais do banco de dados ASHRAE, é possível utilizar as informações coletadas e, através da acurácia da rede neural artificial (RNA) generalizar para as percepções térmicas estimadas e depois compará-las com as percepções observadas através da modelagem.

O método de Rede Neural Artificial (RNA) usado consiste no aprendizado da rede a partir dos dados existentes e fornece uma modelagem que pode ser usada para prever o conforto térmico, especificamente a sensação térmica.

Este estudo apresenta códigos em linguagem computacional *Python* com as bibliotecas *TensorFlow* e *Keras* para criar um modelo de conforto térmico utilizando percepção térmica, através da técnica de Rede Neural Artificial Multicamadas *Feed-Forward* (DFF).

Como **objetivo geral** tem-se:

- Desenvolver um modelo de RNA para avaliação do conforto térmico, usando o banco de dados da ASHRAE *Global Thermal Comfort*.

Para atingir este objetivo foram definidos os seguintes **objetivos específicos**:

- Seleção dos parâmetros relevantes para a modelagem;
- Ajuste dos hiperparâmetros de configuração da RNA;
- Treinamento e teste da RNA;
- Comparação dos resultados da RNA de percepção térmica observada e estimada;
- Avaliação da acurácia da rede;
- Generalização da RNA.

2. REVISÃO BIBLIOGRÁFICA

Neste capítulo serão revistos os conceitos de meteorologia e climatologia, climatologia urbana, Ilhas de Calor Urbana e conforto térmico para relacionar com a análise e modelagem microclimática de sistemas urbanos.

2.1. METEOROLOGIA E CLIMATOLOGIA

O interesse sobre as variações térmicas, em diversas partes do mundo, acontece desde a antiguidade. Basta observar que o homem sempre fez associações entre o movimento dos astros e a mudança das estações, tanto para plantar e colher, quanto para se orientar.

No ano 350 a. C., Aristóteles escreveu um Tratado de Meteorologia sobre o planeta e os fenômenos atmosféricos (AGIRRE, 1997). Para ele, os fenômenos da atmosfera eram controlados pelo movimento dos astros. Observando a duração dos dias e das noites e as diferenças nas estações, ele pode concluir que aquele movimento afetava a atmosfera terrestre e provocava mudanças nas condições de frio e calor na superfície da terra.

A partir desse interesse, a meteorologia se desenvolveu como ciência que estuda o comportamento termodinâmico da atmosfera.

Partindo do campo das ciências naturais da física e da química, Ayoade (2001) afirma que a meteorologia é a ciência que estuda os fenômenos atmosféricos, que ocorrem especialmente na troposfera, com a formação de nuvens, tornados, descargas elétricas, entre outros e suas relações com a superfície terrestre e com os oceanos. A atmosfera envolve todo o planeta, desta forma, o que acontece em determinado lugar é sempre influenciado pelo que acontece a centenas ou milhares de quilômetros dali.

Historicamente, estes fenômenos puderam ser melhor estudados a partir da criação de instrumentos como o termômetro, em 1593, por Galileu, e do barômetro de mercúrio, em 1643, por Torricelli.

Em um estudo histórico de meteorologia de Fernandes (2020), ela aponta que após a invenção do telégrafo elétrico, em 1837, o compartilhamento de dados e informações meteorológicas possibilitou grande avanço nas previsões do tempo. O pioneiro Robert Fitzroy utilizou os dados recebidos via telégrafo para emitir avisos de tempestades na região costeira em 1860. Em 1861, ele passou a publicar previsões diárias no jornal *The Times*, em Londres.

No início do século XX, com a invenção do rádio, informações meteorológicas passaram a ser disseminadas com maior agilidade e começaram a ser realizadas transmissões de previsões do tempo para as embarcações. A primeira transmissão de um boletim de previsão do tempo via rádio foi realizada em Boston, em 1925, e pela televisão em 1936, na BBC (FERNANDES, 2020).

Ainda no ano de 1883, o austríaco Julius Von Hann introduziu o conceito de climatologia, estudando o comportamento médio dos elementos atmosféricos (temperatura do ar, umidade relativa do ar, velocidade e direção do vento, precipitação pluviométrica e pressão atmosférica) ao longo de um período extenso de observação, sendo que estas variáveis climáticas oscilam no tempo e no espaço. Este conceito clássico de climatologia foi apresentado em sua obra "*Handbuch der Klimatologie*" que contou com quatro volumes publicados ao longo dos anos. Desta forma, a climatologia se tornou uma ciência aceita pela academia.

Surgiu, então, uma distinção entre a meteorologia que se ocupa dos fenômenos de movimento do ar que acontecem na atmosfera associados às formas de transferência de calor, e a climatologia, que se ocupa dos fenômenos climáticos de temperatura, precipitação, radiação e vento, tendo como base as descrições e padrões de distribuições temporais e espaciais destes elementos medidos por um longo período, conforme Cunha e Vecchia (2007).

A meteorologia e a climatologia possuem muitas semelhanças, mas se diferem na metodologia, conforme Ayoade (2001). O meteorologista emprega a física e a matemática nos processos atmosféricos, enquanto o climatologista utiliza técnicas estatísticas para retirar informações sobre o clima, a partir das observações do tempo.

Pode-se dizer que o meteorologista estuda o tempo e o climatologista estuda o clima. Uma diferenciação de tempo e clima foi apresentada por Monteiro (1976) e Danni-oliveira e Mendonça (2007). O tempo é o comportamento que se apresenta de maneira momentânea na atmosfera através de registros das condições meteorológicas em um determinado instante atual. Já o clima é entendido a partir de um conjunto de registros meteorológicos ao longo de vários anos, compondo uma série histórica coletada por um período mais longo, e pode ser semelhante em outras regiões do planeta que tenham mesmas características.

De acordo com Sorre (1957), a concepção dinâmica de clima enfatiza uma série de movimentos atmosféricos em várias escalas espaciais, com observações contínuas por longos períodos, particularmente na circulação geral da atmosfera, pelo paradigma do ritmo de sucessão habitual dos estados atmosféricos, enquanto que Ayoade (2001) define o tempo como o estado médio da atmosfera numa porção de tempo e em determinado local. Para ele, o clima abrange um maior número de dados do que as condições médias de tempo. Ele inclui os desvios em relação às médias (variabilidade), condições extremas e probabilidade de ocorrer um evento. Desta forma, o clima apresenta uma generalização, enquanto o tempo lida com eventos específicos.

Segundo Varejão-Silva (2006), a temperatura atmosférica indica o grau de aquecimento da atmosfera, a partir de um conjunto de medições de temperatura obtidas a diferentes níveis da atmosfera terrestre. Esses valores são influenciados por uma série de fatores, incluindo: radiação solar, umidade, latitude e altitude. A latitude regula a quantidade de radiação solar disponível e a altitude regula a coluna de ar sobre o local (OKE et al., 2017).

A energia solar que chega à superfície da Terra pode ser considerada um fator muito importante no desenvolvimento dos processos físicos que determinam as condições do clima, especialmente nas áreas urbanizadas.

Observando que o clima na Terra tem um comportamento cíclico, de períodos glaciais e interglaciais, foi possível verificar que as mudanças na temperatura do globo terrestre possuem diversas causas, entre elas, o nível de atividade solar, os

impactos de meteoros, as variações na órbita da Terra, as erupções vulcânicas e a ação antrópica (CHALINE, 1985).

Para se determinar o clima em eras passadas, Hamblin e Christiansen (1995), explicam que os paleoclimatólogos utilizam técnicas, como o estudo de geleiras, fósseis, sedimentos e rochas, além da datação absoluta usando a radioatividade do Urânio 238 e do Carbono 14. Com estas técnicas é possível saber quando e onde as mudanças climáticas ocorreram e concluir que estas mudanças provocaram diversas consequências para os seres vivos, nas lavouras, no nível de rios e mares, seca e inundações, efeito estufa, entre outros.

Segundo Frota e Schiffer (2001), fatores atmosféricos (como radiação solar, ventos, nebulosidade e ponto de orvalho) devidos ao movimento do planeta e dos astros e fatores geográficos (como latitude e topografia) podem interferir na vida terrestre. As consequências provenientes da interação atmosférica e da ação antrópica causam problemas como dispersão da poluição do ar, inversão térmica, formação de Ilhas de Calor Urbanas (ICU), desconforto térmico e problemas naturais como terremotos, maremotos e inundações.

Cada profissional irá aplicar esses conceitos para uso específico em sua área de atuação. Assim, engenheiros e arquitetos aplicam as informações no desenvolvimento de projetos de climatologia urbana.

Deste ponto de vista, torna-se imprescindível a adequação do espaço urbano e das edificações às diferenças geográficas de cada região para minimizar os impactos físicos e as perdas humanas devido aos fenômenos atmosféricos.

2.1.1. Classificação Climática

A classificação climática de Köppen–Geiger (1900) é uma tentativa de reunir o maior número de elementos possíveis que possam caracterizar os diferentes climas existentes no planeta Terra. Esta classificação relaciona o clima com a vegetação, pluviosidade e temperatura a partir de critérios numéricos.

O modelo foi revisado em 1918, dando maior atenção à temperatura, à precipitação pluviométrica e às características sazonais. Estabeleceu-se assim cinco tipos climáticos principais, designados pelas letras maiúsculas (McKNIGHT and DARREL, 2000):

- A – Climas tropicais chuvosos
- B – Climas secos
- C – Climas temperados chuvosos e moderadamente quentes
- D – Climas frios com neve-floresta
- E – Climas polares

Onde:

- A – a precipitação pluvial é maior que a evapotranspiração anual e o mês mais frio tem temperatura média superior a 18° C;
- B – a evapotranspiração média anual é maior do que a precipitação anual;
- C – a temperatura média varia entre -3° C e 18° C no mês mais frio;
- D – com temperatura média abaixo de -3° C o mês mais frio e temperatura média maior do que 10° C para o mês mais quente;
- E – temperatura média menor do que 10° C para o mês mais moderadamente quente.

A estas letras adicionou-se outro grupo, e esta classificação ainda passou a ter duas subdivisões. A primeira realizada pela distribuição sazonal de precipitação:

- f – úmido o ano todo (A, C, D);
- m – de monção, breve estação seca com chuvas intensas durante o resto do ano (A);
- w – chuva de verão (A, C, D);

- S – estação seca de verão (B);
- W – estação seca de inverno (B).

As outras letras referem-se às características para a temperatura:

- a – verão quente, temperatura média acima de 22° C;
- b – verão moderadamente quente, sendo o mais quente com média inferior a 22° C;
- c – verão breve e moderadamente frio;
- d – inverno muito frio, para o mês mais frio.

E para as regiões áridas (BW e BS), temos as siglas:

- h – quente, temperatura média anual maior que 18° C;
- k – moderadamente frio, com temperatura média anual menor que 18° C.

Sendo possível observar suas variações a seguir:

- A – Climas tropicais chuvosos
 - Af - Clima tropical chuvoso de floresta
 - Aw - Clima de savana
 - Am - Clima tropical de monção
- B – Climas secos
 - BSh - Clima quente de estepe
 - BSk - Clima frio de estepe
 - BWh - Clima frio de deserto
- C – Climas temperados chuvosos e quentes

- Cfa - Úmido em todas as estações, verão quente
- Cfb - Úmido em todas as estações, verão moderadamente quente
- Cfc - Úmido em todas as estações, verão moderadamente frio e curto
- Cwa - Chuva de verão, verão quente
- Cwb - Chuva de verão, verão moderadamente quente
- Csa - Chuva de inverno, verão quente
- Csb - Chuva de inverno, verão moderadamente quente
- D – Clima frio com neve-floresta
 - Dfa - Úmido em todas as estações, verão quente
 - Dfb - Úmido em todas as estações, verão frio
 - Dfc - Úmido em todas as estações, verão moderadamente frio e curto
 - Dfd - Úmido em todas as estações, inverno intenso
 - Dwa - Chuva de verão, verão quente
 - Dwb - Chuva de verão, verão moderadamente quente
 - Dwc - Chuva de verão, verão moderadamente frio
 - Dwd - Chuva de verão, inverno intenso
- E – Climas polares
 - ET - Tundra
 - EF - Neve e gelo perpétuos

Durante o período de aproximadamente 30 anos as informações climatológicas foram reunidas para se ter a informação média dos dados característicos da região em

estudo, compondo as Normais Climatológicas que apresentam valores médios calculados para um período relativamente longo e uniforme, compreendendo no mínimo três décadas consecutivas.

Observando a classificação climática de Köppen–Geiger e conforme Ayoade (2001), os fatores que influenciam o clima são: latitudes, altitudes, correntes marítimas, continentalidade e maritimidade, vegetação, massas de ar e particularmente nas cidades, a urbanização. Logo, todos esses fatores serão formadores do clima de determinada região.

Com a utilização de imagens e mapas ficou muito mais simples descrever as condições do tempo, a partir de uma rede de observações, e utilizando modelos numéricos de previsão do tempo foi possível antecipar a influência dos eventos atmosféricos no cotidiano da sociedade.

A classificação climática de Köppen–Geiger considera que os fatores que influenciam o clima têm uma abrangência que se estende por uma área geográfica considerável, ou seja, por mais de uma cidade.

Porém, para estudar o clima específico nas cidades, é necessário investigar o microclima característico dos espaços urbanos e do seu entorno, como tratado a seguir.

2.2. CLIMATOLOGIA URBANA

2.2.1. Histórico sobre Climatologia Urbana

A escala microclimática apresentada nas cidades não deve ser confundida com a classificação climática de Köppen–Geiger, apresentada anteriormente. Isso porque os fatores que influenciam o clima têm uma abrangência maior, uma amplitude que se estende por uma área geográfica considerável, ou seja, por mais de uma cidade. E os fatores que influenciam o clima urbano são mais restritos às características das ruas e do seu entorno.

Muitos pesquisadores se dedicaram a pesquisas sobre o clima urbano. Com base em apanhados históricos, João Lima Sant'Anna Neto (2001) em sua tese “História da Climatologia no Brasil”, Hugo Segawa (2003) em “Clave de Sol: notas sobre a história do conforto ambiental”, João Afonso Zavattini (2003) em “A produção brasileira em climatologia: o tempo e o espaço nos estudos do ritmo climático”, mostraram a contribuição de estudiosos da Europa e dos Estados Unidos com seus trabalhos. Segue uma abordagem histórica.

Segundo Oke (2017), o estudo científico da climatologia urbana se intensificou no século XIX, com o trabalho de campo em algumas cidades. As escalas da climatologia a nível micro e local foram sendo mais conhecidas, e de 1965 até cerca de 2000, houve um aumento significativo no interesse da pesquisa bioclimatológica e de modelos baseados na física da atmosfera urbana. No século XXI a climatologia urbana e a meteorologia puderam contar com a computação e o desenvolvimento da aprendizagem de máquina, para melhorar o processo de análise das variáveis climáticas e associá-las ao conforto térmico.

Luke Howard (1772-1884) foi considerado o precursor da meteorologia e classificação dos tipos de nuvens, além de estudar a climatologia urbana, identificando alterações na atmosfera urbana de Londres (Inglaterra) relacionadas à ocorrência de Ilhas de Calor Urbana (ICU), que representa a diferença de temperatura entre a área urbana e seus arredores não-urbanizados. As ICU começaram a chamar a atenção após o crescimento das indústrias em toda a Europa, devido à péssima qualidade do ar e às mortes em função disso. Howard notou que a temperatura do ar nas cidades era bem maior que na zona rural e que a umidade relativa e a velocidade do vento eram menores, e isso provocava desconforto térmico. A partir de suas observações, vários estudos foram feitos para relacionar conforto térmico com o clima urbano e a formação de ICU.

Na região de Paris, no observatório de Montsouris, Emilien Renou (1815-1902) estudou os efeitos das ICU. Este observatório tem um dos mais antigos e completos bancos de dados disponíveis sobre o clima da França e pode ser usado para as análises climáticas sobre a cidade.

Usando um transecto móvel para traçar o perfil térmico da cidade, Wilhelm Matthäus Schmidt (1883-1936) atravessou a cidade de Viena, capital da Áustria, e obteve um mapa espacial da distribuição da temperatura do ar, que serviu para justificar o desconforto que as pessoas sentiam.

Por volta de 1900 iniciam-se os primeiros estudos do clima urbano no Japão, na China, na Rússia e na América do Norte. As pesquisas surgem como fruto do interesse pela condição atmosférica dos centros urbanos nas grandes cidades e as consequências, algumas vezes, provocadas pela queima de carvão e madeira pelas fábricas ou pela rápida expansão, gerando anomalias térmicas nos centros com maior atividade antrópica.

Nos Estados Unidos, Ellsworth Huntington (1874-1947) contribuiu para o avanço teórico, metodológico e epistemológico na obra “Civilização e clima” de 1915, abordando aspectos meteorológicos que interferem no conforto das edificações urbanas.

A partir da década de 1960, Timothy Richard Oke estuda o clima urbano contribuindo com bases conceituais, teorias, descobertas, métodos e modelos que vigoram até os tempos atuais. Ele atuou na Universidade de Bristol no Reino Unido e na Universidade McMaster no Canadá.

Suas pesquisas dos processos meteorológicos associados à mecânica dos fluidos, especialmente sobre a Camada Limite Urbana, contribuem para o conhecimento científico do comportamento dos fenômenos climáticos. Através de suas observações ele pode concluir que a avaliação dos parâmetros físicos do dossel urbano, do transporte turbulento, do balanço de energia, da rugosidade da superfície e a influência da verticalização das cidades no microclima podiam contribuir para entender a formação das Ilhas de Calor Urbanas. Em suas análises, o uso de métodos estatísticos e modelagens matemáticas, para discutir suas observações e as implicações no nível de conforto que as pessoas sentiam, foram primordiais para o avanço da ciência.

Na área de conforto térmico, Povl Ole Fanger (1934-2006) foi um dinamarquês que se dedicou às pesquisas nesta área. Observando os estudos de seus antecessores, suas pesquisas serviram de base para a padronização internacional da Norma de conforto térmico através da ISO 7730/1984 (atualizada em 2005).

A partir da década de 1980, Sue Grimmond pesquisou os efeitos climáticos nas cidades e estudou o clima urbano e a interferência em seu entorno. Publicou mais de 240 artigos e ocupou altos cargos na área da Climatologia e Meteorologia em vários países.

Estes estudos contribuíram para classificar as estações e tentativas de relacionar estatisticamente as distribuições térmicas às características da paisagem urbana e formas de controles do clima de diversas cidades de clima temperado e estudos estatísticos associadas ao conforto térmico. Essas pesquisas contribuem para mitigar o problema das ICU e tornar possíveis alternativas que atenuem o calor provocado pelo fluxo de energia solar.

Seguindo as pesquisas desenvolvidas na Europa, nos Estados Unidos, no Japão e em outros países, cientistas brasileiros contribuíram para o desenvolvimento dos estudos climatológicos no Brasil, tentando adaptar os problemas do clima temperado daquelas regiões para atender a realidade do clima tropical brasileiro.

As cidades tropicais e equatoriais, no entanto, permaneceram com pouco estudos até o trabalho pioneiro de um dos primeiros brasileiros a se dedicar à pesquisa dos fenômenos climatológicos na década de 1920, Carlos Augusto de Figueiredo Monteiro, geógrafo, que apresentou a análise rítmica do clima, aplicando suas considerações às diversas escalas temporal e espacial. A partir de dados meteorológicos diários da precipitação, temperatura do ar e umidade relativa associado aos sistemas atmosféricos atuantes identificam-se as anomalias climáticas. Monteiro observou que existe um ritmo pulsante atuando em toda a dinâmica climatológica com encadeamento sucessivo e contínuo. Daí a importância da análise das séries históricas climatológicas.

Além dele, o engenheiro hidráulico Paulo Accioli Sá (1934), preocupado com o ganho térmico das estruturas, buscou materiais alternativos para as construções. Em seus estudos, publicou artigos que vieram a estabelecer índices relacionados às sensações de conforto térmico.

Já nas décadas de 1930 e 1940, os estudiosos da meteorologia brasileira, Sampaio Ferraz, Adalberto Serra e Leandro Ratisbona estudaram a circulação atmosférica sobre o país e sobre a América do Sul, e sua atuação local pôde contribuir com pesquisas sobre chuvas e secas relacionadas ao relevo e à superfície de cada região estudada.

Magda Adelaide Lombardo (1984) estudou as Ilhas de Calor Urbana (ICU) nas metrópoles do Brasil, especificamente em São Paulo, usando satélite NOAA e Landsat.

Ana Maria de Paiva Macedo Brandão, atuando desde os anos 1980 na área climatológica, estudou em 1996 as oscilações climáticas na área metropolitana do Rio de Janeiro.

Com um enfoque voltado para os países de clima tropical, José de Oliveira Ayoade em “Introdução à climatologia para os trópicos” (1996) aponta a dinâmica climática específica destas áreas. Ele faz uma abordagem de todos os aspectos da climatologia geográfica e a correlação existente entre as modificações climáticas e as atividades antrópicas.

Em Cuiabá (MT), o Programa de Pós-Graduação em Física Ambiental da UFMT desenvolve pesquisas de Análise e Modelagem Microclimática em Sistemas Urbanos. O Programa se dedica ao desenvolvimento de projetos para melhorar o conforto térmico em espaços urbanos através do aperfeiçoamento e criação de circuitos, algoritmos e aplicação de softwares para medições de variáveis bioclimáticas. Diversos trabalhos têm contribuído para o avanço da pesquisa integrando o conhecimento multidisciplinar.

Várias pesquisas na área de conforto térmico e Ilhas de Calor Urbano que estudam a Microclimatologia voltada para edificações são desenvolvidas por todo o Brasil. Em

São Paulo (SP), a Faculdade de Arquitetura e Urbanismo (FAU) da USP apresenta a linha de pesquisa: Conforto Ambiental, Eficiência Energética e Ergonomia em que desenvolve estratégias de planejamento do espaço urbano e de edificações de forma ambientalmente eficiente e adequada. Em Fortaleza (CE), o Departamento de Geografia da UFC desenvolve o projeto de pesquisa: Estudo do Clima Urbano buscando propor soluções para os impactos que as variações climáticas provocam no espaço físico. Em Curitiba (PR), o Departamento de Geografia da UFPR na linha de pesquisa Produção e Transformação do Espaço Urbano e Regional faz pesquisas sobre conforto térmico e planejamento do espaço. Em Porto Alegre (RS), a Faculdade de Arquitetura da UFRGS possui o Laboratório de Conforto Ambiental (Labcon) que estuda Bioclimatologia na arquitetura. Em Belo Horizonte (MG), o Departamento de Geografia do Instituto de Geociências da UFMG pesquisa a Climatologia Urbana e também o Programa de Pós-graduação em Ambiente Construído e Patrimônio Sustentável (PACPS). Em Santa Catarina (SC), o Laboratório de Eficiência Energética em Edificações (LabEEE) vinculado – ao Núcleo de Pesquisa em Construção do Departamento de Engenharia Civil da Universidade Federal de Santa Catarina – atua visando reduzir o consumo de energia em edificações novas e existentes sem reduzir o conforto térmico.

O Laboratório de Eficiência Energética em Edificações (LabEEE) da UFSC é referência em pesquisas de conforto térmico e trabalha com projetos voltados para o uso eficiente da energia elétrica e dos materiais de construção aplicados às edificações e sua relação dinâmica com o entorno através das interações microclimáticas, distribuição das construções no espaço urbano e os efeitos das Ilhas de Calor Urbano (ICU).

Diversos pesquisadores no Brasil (Roberto Lamberts, Christhina Maria Candido, Renata De Vecchi, Anésia Barros Frota, Loyde Vieira de Abreu Harbich, Lucila Chebel Labaki, Paulo José Lima Perillo, Andreas Matzarakis, Sueli Ramos Schiffer, Eleonora Sad de Assis, Antonio Augusto de Paula Xavier, Wagner Augusto Andreasi, entre outros) têm contribuído para o avanço da pesquisa em climatologia urbana e conforto térmico.

Em países da América Central, a pesquisa também foi desenvolvida pela dificuldade de comparação com os estudos dos países do Norte, com clima diverso. Com isso, estabeleceu-se bases para analisar diferentes tipos climatológicos associados com a morfologia das cidades da América Central. Ernesto Jáuregui Ostos, na Cidade do México e em Guadalajara, contribuiu com estudos de climatologia urbana mostrando a realidade da pesquisa em países em desenvolvimento (JÁUREGUI, 1973).

Observa-se que a literatura sobre o clima urbano cresceu consideravelmente. Conforme as observações de Oke et al. (2017), antes da década de 1960 eram menos de 30 publicações por ano, mas no final do século XX cresceu para cerca de 140 por ano. Este marco não é bem estabelecido, mas nota-se que a busca por soluções reais com aplicação prática da física fez com que as pesquisas nos processos de microclima urbano crescessem. A demanda por novos equipamentos de medição e a evolução das ferramentas tecnológicas contribuíram para o grande armazenamento de dados, que começou a ser gerado, e pela modelagem numérica dos parâmetros climatológicos. Além disso, as questões ambientais ligadas à área urbana como poluição do ar, engenharia eólica, hidrologia e a climatologia de edifícios ganharam destaque e passaram a ter sua divisão na literatura, o que é considerado um grande avanço para a pesquisa científica. O aumento do financiamento de pesquisa levou a uma explosão de publicações.

2.2.2. Climatologia Urbana e suas Influências

A partir do conceito amplo de clima, pode-se vislumbrar uma nova perspectiva, uma vertente mais específica para as cidades, conforme observações de Howard (1818), precursor da climatologia urbana.

Entre os elementos do clima que mais sofrem variações devido à influência da urbanização, a temperatura do ar, a velocidade do ar e a umidade relativa do ar têm-se destacado nos estudos sobre o clima urbano. Características comuns das cidades, como a rugosidade, o uso e ocupação do solo, a impermeabilidade, o albedo de superfície e as propriedades térmicas dos materiais de construção promovem,

variação da velocidade do ar e o aumento da temperatura, tanto no ar, quanto na estrutura urbana, e conseqüentemente, a redução da umidade do ar.

Áreas urbanas influenciam as medidas de temperatura do ar, os padrões do vento e a qualidade do ar, da mesma forma como podem afetar o desenvolvimento das nuvens e da precipitação, segundo Carraca e Collier (2008). A população residente nas cidades pode sentir os efeitos do aumento da temperatura média do ar e da alteração nos padrões de precipitação devido à urbanização.

Conforme pesquisas de Howard (1818), o calor artificial produzido por uma população aglomerada, pelas indústrias e pelo consumo de grandes quantidades de combustível fóssil modifica a temperatura local. A modificação da paisagem natural pela ação antrópica, que edifica o espaço para que o homem possa viver nos centros urbanos e exercer suas atividades, também modifica o microclima.

Segundo Oke et al. (2017), a climatologia urbana estuda as interações entre a cidade e a atmosfera que circunda este espaço. O desenvolvimento urbano transforma tão profundamente a paisagem existente que uma cidade possui seu próprio microclima, que é um amálgama de vários microclimas, cada um deles sofrendo a influência de seu entorno imediato.

Já Khalil et al. (2018), explicam que os fatores que mais influenciam a criação de um clima urbano incluem armazenamento de energia, aumento da rugosidade e menor evaporação.

Para Oke et al. (2017), os climas urbanos são controlados por eventos climáticos sinóticos que, em escalas de tempo mais longas, criam o clima de um lugar. Ventos fracos combinados com céu livre de nuvens suportam o desenvolvimento de efeitos térmicos no clima. Ventos mais fortes, por outro lado, diluem os efeitos térmicos devido aos efeitos de fluxo mecânico. Ventos e nuvens ainda mais fortes amortecem o aquecimento e agitam a atmosfera, de modo que os efeitos urbanos são praticamente destruídos, exceto aqueles devidos à aspereza das cidades.

Os fenômenos físicos – associados à dinâmica da Camada Limite Atmosférica (CLA) ou Camada Limite Planetária (CLP) – são estudados pela Mecânica dos fluidos e

pela Termodinâmica. Se não existissem relevos na superfície terrestre, os fluidos que formam a atmosfera circulariam de forma totalmente diferente ao observado no entorno do planeta. Isso porque os fluidos sofrem influência das leis da termodinâmica enquanto que os sólidos são influenciados pela gravidade. Acima da CLA, os efeitos da fricção aerodinâmica, aquecimento e resfriamento da superfície são pouco sentidos, predominando um escoamento laminar e perturbações atmosféricas em escala sinótica, como as variações associadas às frentes-frias, são percebidas em macro escala (OKE, 1978).

A Camada Limite Atmosférica (CLA) ou Camada Limite Planetária (CLP) é a camada inferior da troposfera em contato direto com a superfície terrestre, que apresenta uma espessura de 1 a 2 km (no caso da camada limite convectiva ou diurna) e entre 0 e 100 m (para a camada limite estável ou noturna). Conforme Oke (1978), durante o dia a turbulência na CLA é devida aos fatores térmicos provocados pela radiação solar (convecção térmica) e durante a noite (período estável), a turbulência tem origem mecânica (gradiente de vento), pois neste período os ganhos solares não estão presentes, mas apenas o calor armazenado nas superfícies do entorno e as trocas convectivas.

A CLA se divide em três partes: camada de transição, camada de mistura e camada superficial. A camada de transição (CT) é a camada no topo da CLA, na qual ocorre a transição entre as condições médias das variáveis e as condições laminares na atmosfera livre, onde não ocorre turbulência fora das regiões instáveis (de cisalhamento do vento) e das térmicas que formam as células de movimento vertical das nuvens. A camada de mistura (CM) é onde ocorre grande mistura devido a difusão turbulenta, que durante o período convectivo da CLA estende-se desde o topo da camada superficial até o topo da CLA (zona de transição), na qual os gradientes verticais médios das variáveis atmosféricas apresentam-se pequenos. A grande mistura turbulenta na Camada Limite Convectiva (CBL: *Convective Boundary-Layer*) ocorre devido ao efeito da convecção térmica diurna, período no qual a superfície da CLA é fortemente aquecida pela radiação solar. A camada superficial (CS) é onde as forças inerciais predominam sobre as viscosas, com espessura da ordem de dezenas de metros, onde ocorrem gradientes verticais intensos

das variáveis atmosféricas médias: temperatura do ar, umidade relativa do ar e velocidade do ar. Dentro dessa camada pode ocorrer uma subcamada rugosa (RSL: *roughness sublayer*), próxima ao solo, na qual o efeito do arrasto aerodinâmico é muito intenso e dominante, e uma subcamada inercial (ISL: *inertial sublayer*), sobre a subcamada rugosa, onde predomina a difusão molecular (viscosidade do ar).

A atmosfera é formada por fluidos constituídos de gases e partículas de líquidos que não possuem seus átomos organizados de forma simétrica e rígida e duas grandezas físicas podem caracterizá-los: massa específica e pressão.

A superfície do planeta é instável para o escoamento dos fluidos, devido à variação da velocidade do vento com a altura, caracterizada pelo cisalhamento e devido à radiação solar que provoca o aquecimento. Estes dois processos são responsáveis pela turbulência atmosférica (MORAES e ACEVEDO, 2004).

A turbulência atmosférica é um processo efetivo de transporte e mistura, devido à intensa variabilidade dos componentes da velocidade turbulenta entre camadas adjacentes. Este é um processo semelhante àquele que causa difusão molecular devido à agitação térmica das moléculas. Entretanto, como a intensidade das flutuações turbulentas é muito maior do que aquela que caracteriza a agitação molecular, o transporte turbulento também é muito mais efetivo que o molecular. Desta forma, como a rugosidade da superfície terrestre provoca turbulência, o entendimento de fenômenos de transporte próximos à superfície está diretamente relacionado a uma adequada caracterização dos fluxos turbulentos (MORAES e ACEVEDO, 2004).

Para estudar a complexidade atmosférica e as trocas de energia são delimitadas as escalas, de acordo com as diferenças da atmosfera a nível de mesoescala, escala local e microescala, conforme Figura 1 a seguir. Segundo Oke (2006), a mesoescala abrange toda a cidade, ou seja, dezenas de quilômetros horizontais e na vertical a espessura da Camada Limite Urbana (CLU). Na escala local, a nível de bairro ou região, a topografia urbana tem influência por alguns quilômetros e na espessura vertical da camada superficial. Na microescala que se estende horizontalmente de um metro a centenas de metros e na vertical a espessura da Camada de Dossel Urbano

(CDU) são encontrados os *canyons* urbanos com suas construções (casas, edifícios e ruas) e os aspectos naturais (praças, parques e espelhos d'água). Observa-se que para tratar de microclima urbano, usa-se a microescala.

A denominação apresentada não diminui a complexidade do sistema climático urbano. Para se medir as variáveis microclimáticas é preciso critérios para seleccionar o local mais adequado para o uso dos instrumentos meteorológicos, já que o sistema urbano é formado por características heterogêneas de paisagem e diferentes tipos de materiais.

Para Oke et al. (2017) o microclima que se apresenta na CDU é caracterizado por uma complexidade considerável, principalmente decorrente das propriedades e diferenciação dos materiais da superfície do entorno que se comportam de maneira distinta quanto à absorção e reflexão da radiação solar. Este microclima muda em função da geometria do *canyon* urbano (por exemplo, traçado da rua, densidade e características dos edifícios) e uso urbano (por exemplo, modos de transporte, tipo de combustível e uso de energia).


Ainda segundo Oke (1978), cada região da cidade terá um microclima diverso como resultado das diferenças no ângulo de incidência solar e no ângulo de ataque do vento. Essas diferenças são adicionais às criadas pelas características radiativas, térmicas e de umidade de seus materiais de construção e pela geometria do *canyon*. Um grande impedimento para o estudo do clima urbano chegar a uma mesma padronização são os efeitos heterogêneos da paisagem urbana e as diferentes escalas de observação.

A atmosfera da cidade torna-se mais aquecida devido à presença de material particulado (poeira, fuligem), liberação de gases (CO₂, CO, vapor de água, entre outros) provenientes de veículos e indústrias, além do calor liberado pela utilização de aquecedores e refrigeradores, pelas observações de Maitelli (1994). Este calor é chamado de calor antropogênico e fica armazenado no dossel urbano. Esse calor também modifica o microclima local.

A cidade é composta por elementos de superfície de tamanhos e composições muito diferentes, estranhos à paisagem natural e modificados pelo homem. Esses elementos são constituídos pela rugosidade da malha urbana, composta por diferentes tipos de construções em alturas diferentes. Para Kalil et al. (2018) as cidades brasileiras possuem configurações distintas e complexas do ponto de vista dos estudos climáticos. As atividades antrópicas trazem impactos ao meio ambiente e à saúde humana, modificando os elementos climáticos que compõem a atmosfera local e favorecendo a formação de anomalias termo-higrométricas nas áreas urbanas, como as ilhas de calor e ilhas de frescor.

Figura 1 - Escalas climáticas horizontais e camadas verticais em zona urbana.

a) mesoescala; b) escala local; c) microescala.



Fonte: adaptado de OKE, 2006.

A modificação do espaço influi no fluxo de energia, água, gases e partículas produzidos pelas fontes antrópicas. A descrição e análise da distribuição espacial e dinâmica do fluxo de ar, temperatura, umidade, gases de efeito estufa e poluentes do ar em áreas urbanas são governadas pela composição da região observada e as trocas térmicas com o meio (OKE ET AL., 2017).

Para Oke et al. (2017), as áreas urbanas sofrem alteração na composição química da atmosfera, nas propriedades térmicas, na hidrológicas da superfície, nos parâmetros aerodinâmicos e nas coberturas naturais do solo que são substituídas por superfícies pavimentadas.

A essência da análise climatológica é separar os dados disponíveis para uma análise estatística compreensível usando médias, variações e diagramas. Para fins de planejamento urbano, esta informação é muitas vezes melhor colocada em forma de mapa para que os dados microclimáticos apareçam e sejam analisados junto com informações sobre uso do solo e outros dados ambientais, que são usados para delinear áreas com resultados climáticos semelhantes.

2.3. CONFORTO TÉRMICO

2.3.1. Conceito de Conforto Térmico

Estudos de Segawa (2003) indicam que no passado, as pessoas adoeciam constantemente, e que os médicos sanitaristas começaram a observar as condições necessárias para que se pudessem viver em ambientes saudáveis como medida profilática para evitar doenças. Eles perceberam que o ar viciado provocava as enfermidades e era preciso tomar medidas sanitaristas para controlar a causa das infecções. Com isso, os engenheiros e arquitetos começaram a projetar espaços com mais ventilação para a entrada de ar fresco e a luz natural começou a adentrar as residências para evitar a proliferação de doenças sazonais. Essas orientações começaram a fazer parte do código de obras dos municípios e contribuíram para o planejamento urbano em muitos centros urbanos. O tamanho dos espaços e das aberturas foram orientados de acordo com a posição do sol, quantidade ideal de

insolação e sombra e ventilação necessárias. O espaço urbano começou a sofrer transformações na largura das vias, posicionamento e altura das construções. O desejável era que o sol matasse os agentes patógenos, mas que não provocasse desconforto devido aos efeitos térmicos.

Essas observações ao longo dos anos serviram para desenvolver melhoramentos ligados ao conforto dos indivíduos em vários aspectos: sanitário, arquitetônico, urbano e principalmente térmico.

Note que o conforto térmico pela ASHRAE/ANSI 55 (2017) representa a satisfação de uma pessoa quando exposta a um determinado ambiente térmico em que ela não sente nem frio, nem calor, enquanto o desconforto térmico pode ser causado pelo resfriamento ou aquecimento do corpo provocando incômodos a ponto dela ter que se abanar ou colocar ou tirar suas vestimentas.

Os seres humanos, que são seres homeotérmicos, possuem um mecanismo corporal termorregulador para manter o equilíbrio térmico com uma temperatura corporal aproximada de 36 a 37 °C (OKE, 1982). Quando a temperatura está abaixo desse valor, há uma tentativa de se elevar a temperatura corporal com vasoconstrição (redução do fluxo de sangue nos vasos superficiais com a circulação sanguínea sendo conduzida para o cérebro e órgãos vitais), tremedeira, arrepios e aumento da taxa metabólica. Quando a temperatura está acima desse valor, a temperatura corporal se eleva provocando vasodilatação (aumento do fluxo sanguíneo) e a produção de suor permitindo que o corpo dissipe calor por evaporação.

O metabolismo do corpo é um fenômeno natural de produção interna de energia que acontece devido à alimentação, pela quebra das moléculas dos alimentos, o que gera calor. Este calor pode ser dissipado por radiação, por convecção (fluxo de calor sensível) ou por condução, que são perdas não- evaporativas ou dissipado por evaporação (fluxo de calor latente) pela respiração e pela pele, conforme Oke (1978).

Se a condição for de extremos de temperatura do ar, considerando a média de temperatura para determinada região, surgirá o desconforto térmico. Em dias muito quentes, haverá uma aceleração na circulação do organismo para irrigar todos os

tecidos e órgãos e para compensar o aquecimento e haver resfriamento do corpo, ocorrendo a liberação do calor na forma de suor. Em dias frios, a circulação sanguínea diminui e para compensar as perdas térmicas do organismo, os pelos arrepiam, o corpo treme e o metabolismo aumenta para impedir o resfriamento e produzir calor (FALZON, 2014). Este mecanismo é conhecido como termorregulação corporal, um processo natural do corpo quando exposto a condições extremas de temperatura para desencadear respostas fisiológicas que auxiliam na manutenção da homeotermia (FROTA e SCHIFFER, 2001).

Conforme Höppe (1987) o processo fisiológico acontece da seguinte maneira, o corpo humano possui termorreceptores, sensores sensíveis a percepção de variáveis climáticas, que mandam mensagens para o hipotálamo regular as trocas de calor do organismo com o meio.


Benzinger (1969), conforme Figura 2 a seguir, mostrou em seus estudos que o hipotálamo envia estímulos elétricos através dos nervos simpáticos que causam a vasoconstrição dos capilares da pele, reduzindo o fluxo de sangue superficial e mantendo o calor do corpo nos órgãos localizados mais profundamente. Esse estímulo também contrai os músculos eretores dos pelos para criar uma camada de ar que gera isolamento térmico, sendo esta ação mais eficiente em mamíferos que possuem o corpo coberto de pelagem. Também ocorrem estímulos nervosos para a contração da musculatura, os chamados tremores, que auxiliam a gerar calor no corpo. A exposição prolongada ao frio pode levar a uma regulação hormonal controlada pelo hipotálamo, que induz a hipófise a secretar o hormônio tireoestimulante (TSH) fazendo com que a taxa metabólica aumente e mais calor seja produzido pelo corpo.

Exposto ao calor, o corpo reage de maneira inversa. Quando o sangue que passa pelo hipotálamo está mais quente que o normal esta região inibe o centro de produção de calor, levando à vasodilatação dos capilares superficiais da pele aumentando o fluxo sanguíneo, o que pode ser o suficiente para regular a temperatura. Porém se o corpo continuar quente os nervos simpáticos enviam um sinal para estimular as glândulas sudoríparas a produzir suor. O suor tem a função de carregar a água para fora do

corpo e por ser um bom condutor de calor, sua evaporação causa o resfriamento do organismo.

Observa-se que o corpo humano é sensível às condições ambientais podendo experimentar conforto ou desconforto térmico em relação às características microclimáticas do entorno e ao isolamento da roupa. Estas condições irão interferir na disposição que as pessoas terão para realizar suas atividades (LAMBERTS et al., 1997).

Figura 2 - Mecanismos de controle de temperatura do corpo.



Fonte: adaptado de Benzinger (1969).

Segundo Hirashima (2014) o conforto térmico está intimamente relacionado às trocas de calor entre o corpo e o ambiente. Nos momentos em que essas trocas ocorrem sem

dificuldades, significa que o indivíduo está se sentindo confortável termicamente e em equilíbrio com o meio. Do contrário, variações bruscas de temperatura provocam incômodos. A causa do desconforto térmico pode ser pelo resfriamento ou aquecimento indesejado do corpo de acordo com as condições climáticas e as sensações individuais de cada um. Além disso, a faixa de temperatura que causa desconforto vai depender de uma série de fatores e do local.

O conforto térmico é influenciado pelo metabolismo corporal, pelas vestimentas e pelas variáveis climáticas: temperatura do ar, temperatura média radiante, velocidade do ar e umidade do ar. Em um ambiente moderado, o sistema termorregulador corporal modificará a temperatura da pele, o fluxo sanguíneo e a transpiração para manter o equilíbrio térmico.

A análise do conforto térmico depende das características físicas das pessoas, do tipo de atividade física desenvolvida, do processo metabólico de produção de energia interna a partir da síntese dos alimentos e do isolamento de roupas.

Embora o equilíbrio térmico possa ser uma condição necessária para o conforto, não é suficiente. Além disso, é função de parâmetros biofísicos (como taxa de suor ou temperatura da pele) e de preferências individuais, que podem estar associadas a contextos culturais, expectativas térmicas e aclimatação. Essas respostas biofísica e psicológica dependem de níveis de atividade, roupas, idade, saúde e assim por diante. Essas respostas são correlacionadas com os dados ambientais para determinar os padrões temporais e espaciais de uso (LAMBERTS et al., 1997).

A vestimenta tem o papel termorregulador de isolar o corpo das perdas e ganhos de energia, ou seja, proporcionar uma maior resistência térmica da pele. Em climas frios, evita a perda de calor do corpo e em climas quentes evita ganhos excessivos. O grau de isolamento depende da estrutura da roupa, incluindo não apenas sua espessura, mas também a quantidade de ar entre ela e a pele. Em climas quentes e secos, a roupa proporciona sombra ao corpo e reflete a radiação solar, se for de cor clara. O tecido deve ter trama fechada para evitar que a radiação penetre na pele, mas grosso o suficiente para fornecer isolamento contra ganhos condutores. Em climas

frios, deve ser grossa e possuir camadas suficientes para manter o ar aquecido, o que serve de isolante térmico.

Com as elevadas temperaturas alguns recursos como o uso de abanadores, ventiladores, ar-condicionado e banhos frios são usados para reduzir a temperatura do organismo. Ao contrário, com baixas temperaturas, a solução é o uso de aquecedores, fogueiras e o uso de vestimentas de pele, couro ou lã para se aquecer e se proteger dentro de ambientes fechados com poucas aberturas.

Desta forma, manter condições térmicas favoráveis é um desafio relativamente fácil dentro das edificações, podendo ser feito um planejamento que se baseia em estratégias passivas ou ativas na elaboração do projeto arquitetônico, porém para espaços abertos, o planejamento é ainda mais complicado, pois envolve situações difíceis de controlar e que exigem maior atenção dos parâmetros associados para controle térmico. Para que os indivíduos se sintam confortáveis termicamente serão necessários cenários que o protejam de possíveis variações que causem desconforto.

O planejamento microclimático para o espaço urbano pode favorecer o uso dos espaços ao ar livre fornecendo proteção contra a exposição solar, com o uso correto de estratégias de sombreamento e ventilação favorecendo, assim, a adaptação e reduzindo o desconforto térmico, enquanto uma resposta inadequada ao projeto do espaço urbano e da envoltória dos edifícios pode piorar o desconforto térmico sentido pelas pessoas.

2.3.2. Métricas de Conforto Térmico

Segundo Vernon & Warner (1932), a identificação da insatisfação térmica está relacionada com o aquecimento ou esfriamento excessivos do ambiente e o conforto individual pode ser considerado aceitável ou não. A partir desta observação, o controle térmico do ambiente construído pode ser configurado para atender à avaliação de satisfação térmica dos ocupantes da edificação através das métricas de conforto térmico.

As métricas de conforto térmico estão associadas a fatores físicos (relacionados aos processos de trocas térmicas e às variáveis climáticas), psicológicos (relacionados às experiências pessoais e às respostas aos estímulos sensoriais) e fisiológicos (relacionados à resposta involuntária do organismo pela termorregulação corporal).

Para De Dear, Brager e Cooper (1997), estes fatores podem ser mudados por alteração no balanço térmico do corpo através de mudança de hábitos na alimentação, atividade física ou vestimenta, de ajustes do ambiente com uso de ar-condicionado, aquecedor ou de protetores físicos contra perda ou ganho de calor e ainda, por adaptação a determinado ambiente, como é o caso da aclimatação.

Um dos principais objetivos dos estudos de conforto térmico é descobrir como o ambiente térmico influencia a percepção térmica dos ocupantes. Daí, diferentes metodologias de pesquisa têm sido utilizadas.

Fanger (1970) descobriu que, em estudos de câmaras climáticas, a sensação térmica média relatada de um grupo de pessoas expostas ao mesmo ambiente térmico era função de quatro variáveis físicas (temperatura do ar, temperatura média radiante, umidade do ar e velocidade do ar) e duas pessoais (índice de resistência térmica das roupas e taxa metabólica).

As variáveis físicas características dos ambientes climáticos observados por Fanger serviram para normatizar as avaliações de conforto térmico através da norma ISO 10551/1995 (Ergonomia do ambiente físico - Escalas subjetivas de julgamento para avaliar ambientes físicos) que busca avaliar o estresse térmico em ambientes quentes, frios e temperados com métodos para medir a reação humana frente às condições microclimáticas e determinar as condições que produzem sensação térmica similar em todos aqueles que respondem à pesquisa.

As variáveis físicas, que são medidas para o cálculo dos índices de conforto térmico, serão apresentadas a seguir.

O conceito de temperatura é discutido por Ayoade (2001), e pode ser descrito, em termos moleculares, como o movimento dessas moléculas. Quanto mais rápido o movimento, maior a temperatura. Em termos relativos ela representa o fluxo de calor

de um corpo para outro. Ela representa ainda, o balanço de energia que entra e sai do sistema pela sua transformação em calor latente e sensível e é medida pelo termômetro.

A temperatura do ar (T_{ar}) é resultante do balanço energético entre a atmosfera e a superfície terrestre em dado tempo e lugar. Os fatores que influenciam a temperatura do ar são: incidência solar, natureza da superfície, localização do ambiente de referência em relação aos corpos hídricos, o relevo, os ventos predominantes, as correntes oceânicas, a altitude e a latitude que controla a quantidade de radiação solar que chega em determinado lugar (AYOADE, 2001).

A umidade relativa do ar (UR_{ar}) é representada em porcentagem pela relação entre pressão parcial de vapor d'água e pressão parcial de saturação do vapor d'água para uma dada temperatura (AYOADE, 2001). Se o ar estiver saturado, a evaporação não é possível e o corpo começa a ganhar mais calor se a temperatura do ar for superior à da pele.

A velocidade relativa do ar (V_{ar}) é descrita por sua magnitude, direção e sentido (AYOADE, 2001). Sua magnitude é mensurada através do anemômetro, enquanto sua direção e sentido são determinados pelo instrumento biruta. O fluxo de ar interfere no conforto térmico devido a troca de calor do corpo com o meio por convecção e por evaporação (LAMBERTS et al., 1997). Desta forma, em climas quentes e úmidos a ventilação trará conforto térmico, pelo processo de evaporação do suor. Já em climas frios ele pode provocar o resfriamento excessivo do corpo e causar desconforto.

A temperatura radiante média (TRM) é a temperatura uniforme de um ambiente imaginário no qual a troca de calor por radiação é igual ao ambiente real não uniforme. É medida na superfície dos objetos expostos e influencia o calor perdido quando o corpo está em contato com superfícies mais frias (HIRASHIMA, 2014). A TRM depende da temperatura do ar, da temperatura de globo, da emissividade do globo e da velocidade do ar (ISO 7726/1998).

A temperatura de globo (T_g) é uma das variáveis das equações de conforto térmico para o cálculo da temperatura radiante média e a mesma corresponde a temperatura que permite avaliar o nível de radiação térmica das superfícies existentes em um ambiente em que a diferença entre a temperatura de globo e a temperatura do ar pode demonstrar certo aumento da radiação térmica no ambiente de trabalho (HIRASHIMA, 2014).

A taxa metabólica (met) representa a energia produzida no tempo (W) por unidade de área superficial do corpo (m^2) e utiliza a unidade met: $1 \text{ met} = 58,2 \text{ W/m}^2$. A energia consumida na manutenção das funções fisiológicas vitais é usada na realização de atividade física (trabalho) e o restante é liberado na forma de calor. Quanto maior a atividade física realizada, maior será o calor gerado por metabolismo (HIRASHIMA, 2014).

A propriedade térmica da roupa ou isolamento de roupa (clo) indica o índice de resistência térmica das vestimentas. Funciona como uma barreira para as trocas de calor por convecção e age proporcionando resistência térmica. A vestimenta tem a característica de ser um isolante térmico, pois mantém junto ao corpo uma camada de ar mais aquecido importante na termorregulação corporal (OKE, 1981). As propriedades físicas do tecido (permeabilidade ao ar, espessura, área de cobertura ou aberturas), ajuste ao corpo e as condições ambientais (frio ou calor) têm impacto sobre a resistência evaporativa das vestimentas, dependendo das necessidades corporais, podendo melhorar a sensação de conforto térmico às variações de temperatura e de velocidade do ar ou piorar essa sensação. A unidade de medida é o clo, em que $1 \text{ clo} = 0,155 \text{ m}^2 \cdot ^\circ\text{C/W}$, representando uma pessoa vestindo um terno completo.

Para quantificar o nível de conforto térmico uma combinação desses aspectos deve ser considerada. Daí, surgem muitos índices para tentar avaliar a satisfação ou insatisfação térmica das pessoas em um ambiente, cada uma considerando uma combinação de parâmetros diferentes.

Diversos índices podem ser usados para calcular o conforto térmico: *Predicted Mean Vote* (PMV), *Predicted Percentage Dissatisfied* (PPD), *Physiological Equivalent Temperature* (PET) e *Standard Effective Temperature* (SET).

O índice PMV da ISO 7730 (2005) prevê o conforto térmico com base na troca de energia entre o corpo humano e o meio ambiente representado pela diferença entre o calor gerado pelo metabolismo e o que foi convertido em trabalho com as trocas de calor ocorridas na pele e sistema respiratório, ou seja, as respostas termofísicas do corpo humano (por exemplo, temperatura da pele e taxa de suor) a estímulos do ambiente (COUTINHO, 1998).


Fanger (1970) desenvolveu um modelo de balanço térmico para a estimativa do PMV e do PPD que apresenta uma base para a avaliação térmica e fisiológica dos componentes climáticos. Sua pesquisa serviu de base para a ISO 7730 (2005). Estes índices se relacionam à avaliação de fatores térmicos e à previsão do número de pessoas insatisfeitas no ambiente, podendo ser utilizadas para verificar se determinada condição térmica satisfaz o critério da sensação de conforto ou desconforto térmico. O modelo PMV de Fanger é baseado em uma derivação do balanço de energia que quantifica o desvio do fluxo de energia líquido do corpo no ambiente de exposição em que o corpo experimentou conforto térmico e é calculado para diferentes combinações de: taxa metabólica, temperatura do ar, temperatura média radiante, velocidade do ar, umidade do ar e isolamento da roupa. O PMV tem como objetivo prever a sensação térmica média de um grupo de pessoas e a respectiva porcentagem predita de insatisfeitos (PPD) com o ambiente térmico.

Segundo Fanger, o índice PMV registra o valor médio dos votos obtidos por um grupo de pessoas que respondem a um questionário, proposto pela ISO 10551 (1995) sobre as percepções relacionadas ao conforto ou desconforto térmico, sobre sensação, preferência, conforto, tolerância e aceitação do ambiente. A PPD apresentada na ISO 7730 (2005) pode ser estimada pelo gráfico da Figura 3 a seguir, em que o aumento do PPD varia de acordo com uma curva representativa para cada valor correspondente de PMV. Observa-se que a PPD de 10% corresponde à faixa de $\pm 0,5$ de PMV. Quando pelo menos 5% das pessoas estão insatisfeitas o PMV é igual a zero, o que significa que a combinação entre condições climáticas (temperatura do

ar, temperatura média radiante, velocidade do vento e umidade do ar), vestimenta e taxa metabólica representa uma sensação térmica neutra, para a média das pessoas. Quando PMV se distancia de zero, o PPD aumenta, o que indica que uma maior porcentagem de pessoas estão se sentindo, seja por frio ou calor.

Os valores de PMV podem variar de muito frio (valores negativos) a muito quente (valores positivos). Por exemplo, valores de PMV de 0,5 são confortáveis, já que menos de 10% da população deve perceber essas condições como muito quentes ou muito frias (OKE et al., 2017).

Figura 3 - Porcentagem de Pessoas Insatisfeitas (PPD) em função do Voto Médio Estimado (PMV).



Fonte: ISO 7730 (2005).

Conforme Gagge et al. (1986), o PMV permite avaliar o conforto térmico, prevendo a sensação térmica para qualquer combinação entre o nível de atividade de uma pessoa (W/m^2), a vestimenta (clo) e quatro variáveis climáticas: temperatura do ar ($^{\circ}C$), temperatura de globo ($^{\circ}C$), velocidade do ar (m/s) e umidade relativa do ar (%).

São consideradas as condições de equilíbrio entre a produção de calor pelo corpo e a perda de calor para o ambiente, a temperatura média da pele e a taxa de suor relacionadas à sensação de conforto em função da taxa metabólica.

O índice PET é um índice climático que considera as influências de todas as variáveis climáticas termicamente relevantes (temperatura do ar, temperatura média radiante, velocidade do vento e umidade do ar) avaliando seu real efeito nos processos regulatórios e no estado térmico do corpo. Isso significa, no entanto, que o PET não pode ser uma medida absoluta de conforto térmico já que depende também da atividade que o indivíduo está desenvolvendo naquele momento.

O índice PET (*Physiological Equivalent Temperature* - Temperatura Equivalente Fisiológica) de um determinado local (dentro da edificação ou ao ar livre) foi desenvolvido por Höpfe em 1987 e calibrado por Monteiro em 2008 para a cidade de São Paulo. Ele representa a temperatura equivalente à temperatura do ar de um ambiente interno padrão (sem vento e sem radiação) em que o balanço de calor do corpo humano é mantido com temperaturas do centro e da pele do corpo iguais às do ambiente de referência (HÖPPE, 1999).

Desse modo, mantém-se o equilíbrio térmico do corpo humano com um metabolismo de trabalho de 80 W/m² (atividade leve, adicionada ao metabolismo básico) e isolamento térmico da roupa de 0,9 clo (unidade medida de resistência térmica oferecida pelo vestuário à troca de calor). As seguintes premissas são feitas para o clima de referência interno: a temperatura média radiante é igual à temperatura do ar ($T_{mr} = T_a$); a velocidade do vento (V_v) é de 0,1 m/s; a pressão de vapor corresponde a 12 hPa (para umidade Relativa de 50% e temperatura do ar de 20 ° C). Considerando um indivíduo médio para homem de 1,75 m de altura e pesando 75 Kg ou mulher de 1,60 m de altura e pesando 60 Kg.

De acordo com uma escala de valores para essa temperatura PET e a sensação térmica do indivíduo nessas condições, determina-se o estresse fisiológico. Esta escala é semelhante à de PMV, porém, os valores são de temperatura equivalente.

A suposição de valores constantes para vestuário e atividade no cálculo do PET foi feita para definir um índice independente do comportamento individual. O que não restringe sua aplicabilidade, pois a variação de roupas e atividades não leva a valores significativamente diferentes de PET.

Outro índice bastante utilizado é o SET (*Standard Effective Temperature - Temperatura Efetiva Padrão*), proposto por Gagge em 1986, que pode ser definido usando um ambiente de referência (TRM = Tar; Var = 0,15 m/s; UR = 0,5; Metabolismo = 1,2 met; Vestimenta = 0,6 clo). O ambiente real e o de referência são equivalentes em termos de esforço fisiológico e de conforto térmico, porque a temperatura da pele e a fração de pele coberta por suor regulatório estão altamente correlacionadas com o desconforto térmico em ambientes frios e quentes. Para a determinação do índice SET é necessária a utilização de um modelo de dois nós de termorregulação corporal, realizando o cálculo das condições de temperatura da pele e fração coberta por suor, para o ambiente de referência, com entrada dos valores encontrados para resolver o sistema de equações e achar a Temperatura Efetiva Padrão (SET) que também pode ser obtida através de modelo analítico teórico de balanço térmico. Este índice apresenta modelagem de dois nós do corpo humano, considerando as trocas entre o núcleo central e a região periférica do corpo e desta com o ambiente externo (GAEGGE et al., 1986).

O PMV, o PET e o SET são construídos no modelo de transferência e equilíbrio de calor. Além disso, WANG et al (2020) explicam que técnicas de regressão também são usadas para mapear as métricas subjetivas para as condições físicas medidas.

Os índices de conforto PMV, PPD, PET e SET geralmente são calculados através do *software* Rayman 2.0 (MATZARAKIS; RUTZ, 2010).

A percepção térmica dos indivíduos quanto ao conforto térmico é um aspecto subjetivo, e se resume em: aceitabilidade térmica, preferência térmica, satisfação térmica e conforto térmico. Representam o quanto de pessoas estão satisfeitas ou não com as condições térmicas do ambiente. As pessoas respondem um questionário e as respostas são computadas e agrupadas para contagem do número de satisfeitos e insatisfeitos. A distribuição dos votos e o intervalo de conforto térmico para a

situação climática apresentada indicam a percepção geral de um grupo de pessoas. Estas métricas de conforto térmico também podem ser usadas para avaliar o nível de conforto ou desconforto a partir da comparação com as condições climáticas.

Para os parâmetros subjetivos, as pessoas respondem a um questionário sobre qual é sua percepção térmica no ambiente analisado. A sensação térmica varia de muito frio (-3) a muito quente (+3) e expressa o quanto de calor ou frio a pessoa está sentindo naquele ambiente. A aceitabilidade térmica pode ser aceitável ou inaceitável. A preferência térmica indica como a pessoa gostaria de estar: frio, neutro ou quente. A aceitabilidade de movimento do ar pode ser aceitável ou inaceitável. A preferência de movimento do ar pode ser: menos vento, nada de mudança ou mais vento. O conforto térmico varia em uma escala de muito desconfortável (-3) a muito confortável (+3). O questionário é testado em um número representativo de pessoas que vão considerar as condições ambientais como termicamente confortáveis ou desconfortáveis.

Observa-se que a sensação térmica e a preferência térmica são métricas em que se podem distinguir entre frio e quente. No entanto, conforme Liu et al. (2019), a satisfação térmica e a aceitabilidade térmica não são capazes de fornecer qualquer informação sobre o sistema de aquecimento, ventilação e ar condicionado (AVAC ou HVAC: *Heating, Ventilating and Air Conditioning*). Uma questão-chave é quais métricas devem ser usadas para medir a experiência térmica em ambientes construídos para que se possa coletar informações adequadas para avaliar a experiência térmica das pessoas.

Veja que a sensação térmica está associada à atividade dos receptores térmicos da pele, enquanto o conforto térmico é considerado dependente de uma resposta termorreguladora de um centro termorregulador. Nesse sentido, após a adaptação, os receptores térmicos da pele podem ser afetados, causando a consequente alteração da sensação térmica. No entanto, o conforto térmico não muda porque é afetado por uma combinação de múltiplos receptores.

Segundo pesquisas de Monteiro e Alucci (2007) as diferenças entre conforto térmico real e os índices de conforto (PMV/PPD, PET e SET) mostram que nem sempre tais índices são os mais indicados para estimar a sensação de conforto em espaços abertos

em cidades de clima quente e úmido, sendo necessária, assim, uma calibração dos índices para maior aproximação com as características climáticas reais ou o uso do conforto térmico real baseado na percepção térmica individual. Isto porque os índices calculados não consideram algumas características individuais das pessoas analisadas ao correlacionar os processos físicos de transferência de calor com um processo subjetivo das pessoas, que são suas sensações. Conforme trabalho de Xavier (2000), que compõe a pesquisa do banco de dados de conforto térmico da ASHRAE, a sensação térmica apresenta mais representatividade com a realidade do que os índices PMV/PPD, o que também foi comprovado por Humphreys and Nicol (1996).

A norma americana ASHRAE 55 (2017) é referência internacional quando se trata da avaliação de conforto térmico em espaços internos. Desde 2004, esta norma apresenta dois procedimentos de avaliação. O primeiro é baseado no clássico modelo analítico de Fanger (1970), por meio dos índices PMV (*Predicted Mean Vote* ou Voto Médio Estimado) e PPD (*Predicted Percentage of Dissatisfied* ou Porcentagem Predita de Insatisfeitos), derivados de experimentos em câmaras climáticas, ou seja, em ambientes controlados. O segundo procedimento é baseado no modelo adaptativo de avaliação e utiliza os fundamentos da teoria de conforto térmico adaptativo, baseada em estudos de campo que relacionam a temperatura de conforto do corpo em função da temperatura do ar externo.

Com a emergência da teoria de conforto térmico adaptativo, diversas limitações quanto à adequabilidade do modelo PMV/PPD para aplicação em espaços urbanos foram discutidas por pesquisadores e muitas questões foram levantadas sobre quantas e quais métricas de conforto térmico deveriam ser usadas. Devido a essa limitação, o uso de RNA tem se mostrado promissor.

O uso dos índices preditivos de conforto térmico ainda gera muita confusão quanto ao seu emprego e divergências entre si, pois consideram aspectos diferentes para as respostas térmicas das pessoas em um ambiente, que vão além de questões fisiológicas e comportamentais. Questões emocionais, aclimação, características regionais, aspectos demográficos e fatores externos também podem influenciar na percepção térmica, dificultando a escolha do melhor critério para se avaliar o conforto térmico.

Regressão linear/polinomial univariada/multivariada e regressão logística são as ferramentas matemáticas mais usadas para identificar a relação entre o ambiente físico e as percepções subjetivas. Além destes métodos estatísticos, métodos computacionais com abordagens de aprendizagem de máquina, como *machine learning*, também podem ser usados para mapear respostas subjetivas ao ambiente físico e identificar tendências ocultas. As técnicas de aprendizado de máquina são realmente mais poderosas do que as ferramentas de regressão na captura de relações não lineares não padronizadas entre variáveis independentes e dependentes.

Todas essas métricas servem para ajudar no planejamento de estratégias de conforto térmico dos espaços construídos. Assim, sabendo que as estratégias naturais, de ventilação natural e sombreamento, contribuem para a economia energética, mas que nem sempre são possíveis, alternativas sustentáveis devem ser avaliadas para proporcionar uma boa correlação entre conforto térmico e eficiência energética.

Com esta visão estratégica aliada ao o conjunto de normas de conforto térmico, desempenho térmico - NBR 15220 (ABNT, 2005) e de eficiência energética (RTQ-C, 2013), esses conhecimentos podem ser usados para gerenciar a tomada de decisão em projetos arquitetônicos e urbanos e oferecer os melhores cenários em que sejam atendidas as necessidades de conforto. Estes aspectos não serão abordados aqui, mas servem para orientar pesquisas futuras que queiram integrar esses conhecimentos. Eles serão importantes para promover diretrizes bioclimáticas relacionadas ao conforto e aos aspectos da construção de forma sustentável.

De acordo com Humphreys e Nicol (1996), as pessoas possuem um mecanismo fisiológico para se adaptar ao ambiente, que se relaciona com as flutuações sazonais da temperatura externa. Assim, as temperaturas de conforto térmico sofrem variações de acordo com o clima local, e as pessoas, quando adaptadas à condição atual do ambiente, aceitam e até preferem a variabilidade térmica dos edifícios ventilados naturalmente. A expansão dos limites da temperatura de conforto térmico proposto pelo modelo adaptativo resultou em iniciativas de racionamento energético em edificações condicionadas artificialmente por meio do ajuste na temperatura (VECCHI, 2015).

Humphreys and Nicol (1996) apontam que a adoção de padrões de conforto térmico referentes à preferência térmica individual, trazem grande economia de energia para efeito de condicionamento de ambientes e sugerem a adoção de uma temperatura interna de conforto baseada na análise dos indivíduos correlacionada à temperatura externa média mensal do local. Com estratégias eficientes, não haveria a necessidade da especificação de uma temperatura interna única e o consumo de energia para o acondicionamento desejável seria mínimo.

Quando o ambiente interno é harmonioso com o externo com variações atmosféricas aceitáveis e livre escolha de estratégias termorreguladoras da temperatura corporal, o intervalo de faixas microclimáticas confortáveis aumenta. Daí, a importância das métricas de conforto térmico para obter desempenho eficiente e prever as condições aceitáveis através das escalas de conforto térmico comparados à satisfação, aceitação e preferência dos indivíduos.

A existência de modelos preditivos de conforto térmico pode possibilitar ao projetista a criação de espaços capazes de manter o conforto térmico das pessoas e o desempenho térmico satisfatório das construções incorporando pesquisas científicas que foram agrupadas em bancos de dados de conforto térmico (SILVA, 2017). Projetos adequados podem permitir o ganho de calor solar no inverno em climas frios e armazenamento de ar frio através de ventilação noturna no verão em climas quentes.

2.4. REDES NEURAIS ARTIFICIAIS (RNAs)

Neste subcapítulo será realizada uma revisão da literatura sobre o assunto, destacando a motivação inicial de seu desenvolvimento e uma explicação sobre a RNA supervisionada usada com retropropagação do erro. Depois serão apresentados alguns estudos que utilizaram métodos de inteligência artificial e sua aplicação na área de conforto térmico ambiental.

2.4.1. Introdução à Inteligência Artificial

Vários cientistas foram levados a buscar formas de desenvolver sistemas inteligentes, capazes de resolver problemas e se basearam na analogia de funcionamento do cérebro humano e sua capacidade de cognição, a partir da ideia de que computadores podem simular o mecanismo de raciocínio e lógica dos seres vivos.

Cientistas da computação juntamente com psicólogos e neurobiologistas tiveram interesse em entender o funcionamento do processo de raciocínio biológico para tentar transformar processos matemáticos em linguagens que o computador entendesse e pudesse executar ações inteligentes baseadas na combinação desses processos.

Com isso, surge a Inteligência Artificial (AI: *Artificial intelligence*), na década de 1950, como um ramo da Ciência da Computação capaz de tornar uma máquina apta a aprender, resolver problemas e realizar tarefas, com o máximo de precisão e eficiência, de maneira automática, conforme Mandic & Chambers (2001). A Inteligência Artificial se baseia na ideia de que sistemas computacionais podem aprender, identificar padrões e tomar decisões com pouca intervenção humana.

A evolução da Inteligência Artificial (AI) tem mudado o jeito que as pessoas interagem com os sistemas e máquinas que utilizam sistemas inteligentes. A forma que resolvem problemas, tomam decisões e fazem previsões futuras tem ajudado o homem em suas tarefas cotidianas ao desenvolver máquinas programadas para executar determinadas tarefas.

Através da observação do que o cérebro humano é capaz de processar, como por exemplo, milhões de informações, pensamentos, sensações, emoções e controles do corpo humano, vários pesquisadores, perceberam uma analogia entre o funcionamento do cérebro e o processamento de dados e tentaram desenvolver sistemas artificiais capazes de realizar funções de classificação, reconhecimento de padrões e processamento de imagens (HAYKIN, 2001).

O conceito de AI se popularizou com Arthur Lee Samuel através do aprendizado de máquina (ML: *Machine Learning*). Este termo sugere que as máquinas são capazes

de aprender a analisar e identificar padrões nos dados através de algum algoritmo de computador, que é a forma de organizar a lógica computacional passo-a-passo (RUNGTA, 2018). Uma das principais ideias por trás do aprendizado de máquina é que o computador pode ser treinado para automatizar tarefas, podendo tomar decisões com o mínimo de intervenção. Fundamentalmente, a aprendizagem de máquina usa algoritmos para extrair informações de dados brutos e representá-los em algum tipo de modelo.

Segundo Lecun et al. (2015), os algoritmos de aprendizagem de máquinas podem ser divididos em três categorias: aprendizagem supervisionada, aprendizado não supervisionado e aprendizado de reforço.

Na aprendizagem supervisionada um modelo aprende a executar uma tarefa a partir de respostas conhecidas (rotuladas) que devem ser repassadas para que o sistema aprenda. Este aprendizado é iterativo e realizado até que uma resposta rotulada seja atingida, ou seja, até minimizar os erros do algoritmo (GÉRON, 2019). Essa condição de parada é possível pois se trata de aprendizado com resultado conhecido.

Nesta aprendizagem, existem duas classes de algoritmos: de regressão (para prever um valor numérico) e de classificação (determinar a categoria que pertence a amostra do problema). Alguns exemplos de técnicas de regressão são: regressão linear, regressão logística, entre outros. Exemplos de técnicas de classificação são: árvores de decisão, algoritmo de Naïve Bayes, e outros.

Já a aprendizagem não supervisionada é usada quando o desafio é descobrir relações implícitas, sem respostas conhecidas (rótulos), em um determinado conjunto de dados. Não se tem os rótulos para passar ao modelo, então, o modelo deduz o conhecimento a partir de uma amostra do problema (GÉRON, 2019).

Na aprendizagem não supervisionada existem três classes de algoritmos: de clusterização (usada para agrupar, com base nas semelhanças encontradas), de associação (descobrimto de regras que frequentemente acontecem entre conjunto de dados) e de redução de dimensionalidade. Alguns exemplos de clusterização: *K-means*, baseado em particionamento, baseado em densidade, hierárquico

aglomerativo e hierárquico divisório. Exemplos de técnicas de associação: *apriori*, *partition*, *eclat*, *FP-growth*, entre outros. Exemplos de redução de dimensionalidade: *Kernel density estimation*, análise de componentes principais, entre outros.

Diferente dos dois anteriores, o aprendizado de reforço é o ensinamento com base na experiência, na qual a máquina deve aprender com seus erros e procurar a abordagem correta, através de um *feedback*. O modelo aprende executando ações e avaliando recompensas que geram o aprendizado e descartando resultados ruins. Geralmente é aplicado quando se conhece as regras, mas não se sabe a melhor sequência de ações que devem ser executadas, elas são iterativamente aprendidas (GÉRON, 2019). Exemplos de aprendizado de reforço: *Q-Learning*, aprendizado por diferença temporal, aprendizado profundo por reforço, entre outros.

Conforme Wang et al. (2020), um dos principais desafios para aplicação da abordagem do aprendizado de máquina é a enorme existência de algoritmos diferentes em cada tipo de categoria. É possível testar as diferentes configurações que permitem a escolha do melhor para ser usado.

Os algoritmos são escritos para que a máquina possa aprender os comandos de forma automática e corretamente. Mandic and Chambers (2001) explicam que existem vários algoritmos de aprendizagem de máquina que podem ser usados para isso, cada algoritmo específico pode representar o comportamento de um sistema e aplicar o que aprendeu com ele. O algoritmo de retropropagação, por exemplo, foi desenvolvido para treinar redes com base em um conjunto de amostras de treinamento de entrada e saída. O algoritmo melhora o desempenho dos modelos através de seu constante aprendizado e treinamento. Estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

As RNAs são algoritmos computacionais que simulam o comportamento do cérebro humano usando o conceito de conexões neurais a partir de neurônios conectados em camadas treinadas para solucionar os mais variados problemas. Usando algoritmos, elas podem reconhecer padrões escondidos e correlações em dados brutos, aprendendo com sua própria modelagem e melhorando continuamente (LECUN et al., 2015). A RNA ajusta esses pesos sinápticos com base nos dados de treinamento

para minimizar uma função de custo ou de perda (*loss function*) pré-selecionada (THEODORIDIS, 2020).

Para Mandic & Chambers (2001) as RNAs são compostas por elementos computacionais não lineares que operam em paralelo, dispostos de uma maneira que lembra as conexões neurais humanas. Seu objetivo é criar modelos computacionais a partir da analogia com neurônios biológicos para simular sistemas complexos que podem ser resolvidos por análise matemática. Cientistas tentam fazer uma ligação entre processos biológicos observados nas sinapses nervosas (mecanismo de processamento e aprendizado biológicos) e os processos matemáticos através da criação de modelos de RNAs para processamento e aprendizado. Os dados são introduzidos na camada de entrada, processados nas camadas ocultas e o resultado fornecido na camada de saída.

Observando que o cérebro recebe o estímulo externo, faz o processamento e gera o resultado, os programadores de dados criaram sistemas parecidos, capazes de também receber estímulos que são tratados como dados de entrada, fazer o processamento destes dados e gerar resultados bastante úteis para a interpretação de problemas. Vários estudos foram realizados para desenvolver máquinas cada vez mais independentes.

Segundo Rungta (2018), Redes Neurais Artificiais (RNAs) compõem uma técnica de aprendizado de máquina que simula o funcionamento do cérebro humano, através da simulação de conjuntos de neurônios e suas conexões. Elas são bem poderosas e apresentam uma inteligência emergente que tem aplicações em problemas complexos do cotidiano, aprendem pelo exemplo e usam bibliotecas de teorias estatísticas e de otimização, complementando as técnicas convencionais de processamento de sinais. A propriedade mais importante da RNA é a capacidade de aprender consigo mesma.

Ao alimentar as entradas com diferentes atributos, ou recursos que os algoritmos precisam entender, e fornecendo um limite de decisão com base nos dados fornecidos, é possível usar os dados para encontrar padrões e fornecer respostas a determinados problemas (KOVÁCS, 2006). Quando o algoritmo aprende e interpreta os dados, ele pode iniciar uma fase de teste e fornecer resultados.

As RNAs podem ser eficientes devido à sua topologia, aprendizado de algoritmos, capacidade de aproximar funções e capturar dinâmicas de sistemas variantes no tempo (MEDLER 1998). Elas podem ser elaboradas para resolver complexidades de diversas situações através da modelagem matemática de dados não-lineares e realizar generalizações, inferências e predições ocultas. Ao invés de lidar com essas complexidades manualmente, as RNAs são capazes de aprendê-las e solucionar problemas com erros cada vez menores, de maneira automática. As RNAs são multivariadas, eficientes com problemas complexos e não lineares, além de poderem apresentar múltiplas entradas e saídas.

As RNAs são um tipo de modelo para aprendizado de máquina que existe há pelo menos 70 anos (PATERSSON & GIBSON, 2017), o que é considerado recente. Todo esse conhecimento das RNAs evoluiu ao longo do tempo e precisou de bastante pesquisa para chegar até a atualidade, trazendo melhorias no processo. Abaixo segue um histórico sobre essa evolução.

Os precursores do estudo de RNAs foram Warren McCulloch (neurofisiologista) e Walter Pitts (matemático). Em 1943, eles modelaram uma rede neural simples usando circuitos elétricos e descrevendo por analogia o funcionamento biológico do cérebro e suas sinapses nervosas com o funcionamento do modelo computacional criado.

Já no ramo da neurociência, em 1949, o psicólogo Donald Olding Hebb (1904 – 1985) escreve o livro *The Organization Behavior*, explicando os processos cognitivos do cérebro em termos de conexões neurais e propõe um esquema de aprendizado em que a conectividade do cérebro é continuamente modificada conforme o organismo vai aprendendo tarefas funcionais diferentes e que agrupamentos neurais são criados por tais modificações.

As pesquisas continuaram e, em 1958, um neurobiologista chamado Frank Rosenblatt, estudando o funcionamento do olho de uma mosca ao fugir, cria o *PERCEPTRON*, um algoritmo para o reconhecimento de padrões baseado em uma rede neural computacional de duas camadas usando operações de adição e subtração. *Perceptron* é um algoritmo de aprendizado para classificações binárias possuindo a

capacidade de resolver problemas linearmente separáveis através do processo de treinamento, no qual o algoritmo aprende a classificar a entrada em dois grupos diferentes.

Rosenblatt no final dos anos 1950 criou uma rede de múltiplos neurônios (discriminadores lineares) e a chamou de *Perceptron* Multicamadas (MLP - *Multilayer Perceptron*). Pode-se ter múltiplos *Perceptrons* em que os neurônios são dispostos em várias camadas possuindo entradas, saídas e camadas ocultas com função de ativação entre as camadas (KOVÁCS, 2006).

Em 1959, Bernard Widrow e Marcian Hoff, de Stanford, desenvolveram modelos denominados “ADALINE” (*ADaptive LINear Elements*) e “MADALINE” (*Multiple ADapted LINear Elements*). ADALINE foi desenvolvido para reconhecer padrões binários de modo que, se ele estivesse lendo bits de transmissão de uma linha telefônica, poderia prever o próximo bit. MADALINE foi a primeira RNA aplicada a um problema do mundo real, possibilitando o desenvolvimento de um filtro adaptativo que elimina ecos nas linhas telefônicas.

A aprendizagem profunda (*deep learning*) foi empregada, pela primeira vez, por Alexey Grigoryevich Ivakhnenko e Valentin Grigoryevich Lapa em 1965, usando funções de ativação polinomial analisadas com métodos estatísticos. Várias camadas ocultas foram empilhadas entre a camada de entrada e de saída, fazendo com que a RNA recebesse a categoria de profunda.

Algumas inovações começam a surgir, e, em 1975, uma rede neural de hierarquia multicamada é proposta por Kunihiko Fukushima usando notações matemáticas chamada NEOCOGNITRON utilizada para o reconhecimento de caligrafia e outros problemas de reconhecimento de padrões.

Em 1982, John Hopfield da Caltech apresentou uma abordagem para criar dispositivos que fossem úteis em várias aplicações mostrando como as redes neurais poderiam funcionar e o que poderiam fazer.

Algum tempo depois, grupos independentes de pesquisadores, dentre eles David Rumelhart, ex-membro do departamento de psicologia de Stanford, apresentaram,

em 1986, as chamadas redes BACKPROPAGATION que distribuem erros de reconhecimento de padrões em toda a rede. As redes híbridas utilizavam apenas duas camadas, enquanto as redes de *Backpropagation* utilizavam muitas camadas. O resultado foi que as redes de *Backpropagation* aprendiam de forma mais lenta, já que necessitavam de milhares de iterações para aprender, mas geravam um resultado mais preciso que as de duas camadas.

Continuando as pesquisas, um algoritmo capaz de reconhecer objetos tridimensionais a partir de séries desordenadas, chamado CRESCEPTRON foi criado por Juyang Weng, em 1992.

É interessante notar que as redes neurais simples dominaram o campo do aprendizado de máquina por quase uma década, de 1986 até meados da década de 1990.

Nos anos 2000, popularizou-se o conceito de aprendizagem profunda (*deep learning*) para extrair recursos expressivos de dados brutos através de modelos que envolvem uma maior quantidade de funções e camadas ocultas quando comparados à aprendizagem tradicional de máquina (VAPNIK, 1995).

Geoffrey Hinton e Ruslan Salakhutdinov, em 2006, mostraram como uma RNA de várias camadas poderia ser treinada uma camada por vez tratando cada uma delas como uma máquina de Boltzmann restrita não supervisionada, e então fazendo ajustes finos por meio de propagação reversa supervisionada (HINTON, 2007).

Para um computador implementar qualquer tarefa de forma inteligente e eficiente, detectar padrões ou fazer cálculos em milésimos de segundos, ele utiliza algoritmos para modelar um conjunto de dados nas camadas de processamento. Os algoritmos são usados para que o computador aprenda de forma automática, sem necessidade de refazer o processo a cada começo. Os dados são inseridos e os algoritmos farão o computador aprender a processar estas informações. O aprendizado profundo exige conjuntos de dados de treinamento e teste extensivos (RUNGTA, 2018).

Em 2009, aconteceu um *Workshop* sobre aprendizagem profunda (*deep learning*) para reconhecimento de voz e descobriu-se que com um banco de dados

relativamente grande, as redes neurais não precisavam de pré-treinamento e as taxas de erro caíam consideravelmente.

Nos anos seguintes da década de 2010, empresas de tecnologia da internet (Google e Facebook, entre outras) começaram a utilizar reconhecimento facial e de voz baseados em aprendizagem profunda.

Várias arquiteturas de *deep learning*, como rede neural convolucional, rede neural recorrente, entre outros, são usadas em áreas para reconhecimento de fala, visão computacional, processamento de linguagem natural, reconhecimento de áudio e bioinformática de maneira eficiente (THEODORIDIS, 2020).

A popularização dessas técnicas impulsionou o mecanismo de construção de sistemas de Inteligência Artificial ao ganhar muitas competições importantes de aprendizagem de máquina, entre elas, em 2018, a disputa de um *match* no jogo de tabuleiro Go entre um *cluster* de computadores programado com RNA híbridas (*AlphaGo* e *AlphaGoZero*, desenvolvidos pela *Alphabet Inc.*), e o campeão mundial, o sul-coreano Lee Sedol, campeão 18 vezes.

Conforme exposto, a evolução da IA, em meio século, foi promissora e continuará trazendo muitas novidades para a aplicação nas mais diversas áreas, o que trará, também, inúmeros benefícios para o dia-a-dia das pessoas.

Embora existam diversas limitações para se desenvolver RNAs mais sofisticadas, com arquiteturas diversas, e consumo de recursos computacionais, nota-se que os processadores estão cada vez mais velozes e melhores para extrair informações dos dados brutos. Um conjunto de dados suficientemente grande podem ser processados com rapidez em *hardwares* dedicados ou em plataformas online, com *clusters* de servidores, obtendo excelentes performances destes sistemas em relação aos convencionais (RUNGTA, 2018).

O uso da IA é abrangente e tem alcançado pesquisas nas áreas da tecnologia, criação de sistemas com diagnósticos médicos, planejamentos e gestão na engenharia, identificação de padrões para modelagem de dados de séries temporais para prever

eventos climatológicos, econômicos ou financeiros, além da criação de cópias de obras de arte e estilos musicais idênticas ao original.

Observa-se que as RNAs são consideradas simples e intuitivas, sendo capazes de realizar uma série de tarefas complexas. Além disso, são muito flexíveis possibilitando resolver os mais diversos tipos de problemas, fornecendo resultados de qualidade. Estas vantagens contribuem para a grande utilização das RNAs atualmente (HUNT et al.,1992).

Desta forma, o uso de sistemas computacionais que imitam a capacidade de cognição do cérebro humano, capazes de aprender, resolver problemas e alcançar seus objetivos, é impulsionado pelas RNAs e ajuda a desenvolver muitos projetos em várias áreas da ciência. Assim, a RNA poderia ser uma alternativa para a tomada de decisão analisando padrões e relacionamentos nos dados por si mesma.

2.4.2. Funcionamento das Redes Neurais Artificiais (RNAs)

A RNA é um ramo da Ciência da Computação que para McCarthy (2004) busca reproduzir o comportamento dos neurônios e sua capacidade de aprendizagem através do reconhecimento de padrões sequenciais que podem ser utilizados para solucionar problemas nas mais diversas áreas, desde a engenharia, bem como a medicina, a economia, a administração, entre outras. Essas possíveis soluções abrem espaço para o uso crescente das RNAs para resolver os mais variados problemas com precisão cada vez maior.


Diferentemente dos programas de computação tradicionais, as RNAs criam redes que serão treinadas para resolver problemas específicos (ANDERSON and MCNEILL, 1992). Estas redes têm a capacidade de responder a estímulos de entrada e aprendem a se adaptar ao ambiente. As diferentes possibilidades de conexão entre as camadas da rede podem gerar inúmeras estruturas diferentes.

Para Patel e Jha (2014) RNAs são sistemas formados por unidades de processamento simples (neurônios artificiais) que calculam determinadas funções matemáticas para

a solução de algum tipo de problema, podendo apresentar melhores resultados do que os tradicionais modelos estatísticos. Os neurônios artificiais se conectam por sinapses (funções de ativação) que estão associadas a determinado peso. As unidades neurais artificiais fazem operações sobre seus dados locais na camada de entrada recebidas pelas suas conexões.

Na Figura 4 a seguir, tem-se a ilustração das sinapses nervosas responsáveis pela troca de informação entre os neurônios biológicos. Por analogia a esta representação, a RNA tenta reproduzir a ideia da propagação de sinais usando algoritmos matemáticos para representar a capacidade do computador aprender.

FIGURA 4 - Neurônios pré e pós-sinápticos, demonstrando a região de acoplamento onde ocorre a sinapse. É possível verificar o sentido de propagação do sinal elétrico entre os neurônios pré e pós-sinápticos.



Fonte: BORGES et al. (2015).

Como o cérebro possui neurônios que transmitem informações através de conexões neurais, o computador analogamente usa algoritmos capazes de transmitir informações por meio de uma rede de neurônios artificiais criados para reconhecer um padrão de informação e transmitir o sinal para outro neurônio, fazendo com que a informação seja propagada.

As RNAs aprendem a executar as tarefas programadas de forma automática usando algoritmos que criam processos metódicos de passo-a-passo para a realização de cálculos, resolução de problemas e tomada de decisões. Quando a tarefa se torna complicada, vários neurônios artificiais formam uma rede complexa para se comunicarem. Esses processos exigem habilidades de planejamento, organização, decisão, análise, síntese, coordenação, percepção do erro e capacidade de correção (HARARI, 2016).

Os neurônios artificiais são caracterizados pelos seus pesos, vieses (*bias*) e funções de ativação e propagação. Por analogia, os dendritos funcionam como as entradas, cujas ligações com o corpo celular artificial são realizadas por meio dos pesos sinápticos que simulam as sinapses. A intensidade das ligações entre neurônios é emulada através de pesos, que são ajustáveis durante o processo de evolução do treinamento da rede. O corpo celular é emulado através da composição de duas funções: ativação e propagação. O objetivo dessas funções é mapear os sinais de entrada, que serão propagados para os neurônios seguintes da rede, tal como um modelo biológico, até que o sinal seja propagado em um sinal de saída (THOMÉ, 2002).

Os neurônios fazem uma transformação linear na entrada usando pesos e *bias* e a transformação não-linear é feita pela função de ativação (DIETTERICH, 1995). A função de ativação recebe o valor de entrada que entra no nó, realiza uma transformação e passa o resultado para o próximo conjunto de neurônios. Para treinar a RNA uma boa estratégia de inicialização para os pesos de conexão e a escolha de uma boa função de ativação são importantes.


Os modelos não-lineares tentam estimar qualquer função com grau de precisão arbitrado e são usados em problemas que a relação entre variáveis não é totalmente conhecida, em problemas de difícil modelagem ou com grande volume de dados para simulação (YASSIN, et al., 2016).

As conexões neurais artificiais costumam se aprofundar e se interconectar (sinapses artificiais representadas por funções matemáticas) formando camadas com o papel de coordenar e organizar as informações através da rede neural (KOVÁCS, 2006). Elas

podem aprender automaticamente, sem conhecimento predefinido pelos programadores e podem modificar sua própria organização (HAYKIN, 2009).

O modelo de neurônio artificial proposto por McCulloch e Pitts, é apresentado na Figura 5, a seguir. Ele apresenta n terminais de entrada (dendritos) com os valores x_1, x_2, \dots, x_n (ativação dos neurônios anteriores) e um terminal de saída y (representando o axônio). Para reproduzir as sinapses nervosas, os terminais de entrada têm pesos (w_1, w_2, \dots, w_n) representados por valores reais que determinam o que o neurônio deve considerar sinal de disparo naquela conexão. O efeito de cada sinapse é ponderado pela multiplicação da entrada pelo peso ($x_i \cdot w_i$). Desta forma, um neurônio de uma RNA é um elemento que calcula a soma ponderada (Σ) de várias entradas, aplica uma função matemática de ativação (g) conforme seu potencial de ativação (u) e passa o resultado adiante para que as variáveis de saída forneçam os resultados obtidos pelas operações matemáticas.

FIGURA 5 - Neurônio Artificial de McCulloch e Pitts.



Fonte: THOMÉ, 2002.

Haykin (2001) explica que este modelo pode incluir um limiar de polarização ou *bias* (Θ) que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação e, conseqüentemente, a capacidade de aproximação da rede, especificando qual será o patamar apropriado para que o resultado produzido possa gerar um valor de disparo de ativação. A soma do valor de entrada ponderado ($\Sigma x_i \cdot w_i$) é comparado com o

valor limite para ativação do neurônio. Caso este valor alcance o limite, ele se ativará, caso contrário, permanecerá inativo. A função de ativação (g) repassa o sinal para a saída do neurônio e decide o que fazer com o valor resultante do somatório das entradas ponderadas, podendo ou não restringir a ativação do neurônio. A função de propagação define e envia para fora do neurônio o valor passado pela função de ativação.


Desta forma, cada camada é tipicamente um algoritmo simples com uma função de ativação. As camadas são conectadas através de uma rede de nós, que podem ser ativados. Essa ativação se espalha através da rede, criando uma resposta ao estímulo. As conexões entre esses neurônios artificiais são como sinapses simples, fazendo os sinais serem transmitidos entre as camadas e serem processados ao longo do caminho. Os neurônios executam cálculos matemáticos para decidir se há informações suficientes a serem enviadas para o próximo neurônio onde as relações mais fortes estão. As entradas de dados recebidas são somadas e, se a soma for maior que determinado limite de valor, o neurônio ativa os neurônios conectados a ele. Os nós nas camadas intermediárias (ocultas) combinam os dados da camada de entrada com um conjunto de coeficientes e atribui diferentes pesos para as entradas que serão somados. A soma passa pela função de ativação de um nó, que determina a extensão em que um sinal deve progredir na rede para afetar o resultado final. Finalmente, as camadas ocultas ligam-se à camada de saída que fornece os resultados (KOVÁCS, 2006).

O processo de aprendizado da rede neural acontece quando a rede entende que sua saída deve ser próxima de um valor esperado e isso é conseguido pela função de ativação. Esta função é uma transformação não-linear ao longo do sinal de entrada e permite alterar os pesos e *bias* fazendo com que a saída transformada seja enviada para a próxima camada até fornecer um resultado como saída, que esteja dentro do esperado (MANDIC and CHAMBERS, 2001). A função de ativação permite a propagação desde que o gradiente de otimização seja fornecido junto com o erro para atualizar os pesos e *bias*, este processo de ajuste é o que muda na RNA e faz com que ela aprenda. Sem a função de ativação, os pesos e *bias* fazem apenas uma

transformação linear, o que limita a resolução de problemas complexos (FAUSETT, 2006).

A Figura 6 a seguir, apresenta uma arquitetura de camada simples com a camada de entrada (onde são inseridas as variáveis), a camada oculta (onde se realizam as transferências de informações através das conexões) e a camada de saída (onde o resultado é apresentado).

FIGURA 6 - Diagrama de uma Rede Neural Artificial (RNA) com camada simples.



Fonte: HAYKIN, 2001.

A arquitetura das redes neurais é organizada em camadas, com unidades conectadas às unidades da camada posterior. Medler (1998) explica que a forma de operação das RNAs pode ser unidirecional (*Feed-Forward: FF*) onde os sinais internos se propagam apenas na direção entrada-saída ou recorrente quando houver a realimentação do referido processo. Nas redes sem realimentação (*Feed-Forward*) os *perceptrons* são agrupados em camadas e o sinal segue uma única direção passando da camada de entrada para a camada oculta e desta para a camada de saída e os *perceptrons* da mesma camada não se conectam. Não há *loops* de *feedback*. Nas redes recorrentes ocorre retroalimentação, ou seja, a saída dos *perceptrons* são entradas de outros da mesma camada, e em seguida, passam o sinal para outras camadas. O sinal percorre a rede em duas direções.

Para Haykin (2001), um *Perceptron* Multicamadas (MLP - *Multilayer Perceptron*) consiste de um conjunto de unidades sensoriais que formam uma camada de entrada, camadas intermediárias e uma camada de saída. Os sinais de entrada são propagados camada a camada pela rede em uma direção positiva (*Feed-Forward*), ou seja, da entrada para a saída. Esta arquitetura representa uma generalização do *perceptron* apresentado anteriormente.

O aprendizado feito por intermédio do algoritmo de retropropagação do erro (*backpropagation*) é baseado numa regra de aprendizagem que corrige o erro durante o treinamento. Os pesos são ajustados de acordo com uma regra de correção do erro. Especificamente, a resposta da rede em um instante de tempo é subtraída da saída desejada para produzir um sinal de erro. Este sinal de erro é propagado da saída para a entrada, camada a camada. Os pesos são ajustados de forma que a distância entre a resposta da rede e a resposta desejada seja reduzida.

Segundo Fausett (2006), no *backpropagation*, o aprendizado resulta da repetição de todas as amostras do conjunto de treinamento, chamado de época, apresentadas durante o processo de aprendizagem. A atualização dos pesos e *bias* em lote (*batch*) é feita após a apresentação de todas as amostras de treinamento que constituem uma época. A utilização do método em lote fornece uma estimativa mais precisa do vetor gradiente. Este processo de aprendizagem é repetido época após época, até que o conjunto de pesos e *bias* se torne estável e haja conversão do erro do conjunto de treinamento para um valor mínimo.

Conforme as camadas ocultas vão crescendo, suas conexões vão se tornando mais profundas e a hierarquia passa a ser importante. Os padrões poderão ser descobertos de forma automática seguindo uma hierarquia de algoritmos simples para que as formas complexas sejam posteriormente aprendidas (LECUN et al., 2015).

Conforme o número de camadas ocultas dentro de uma rede aumenta, RNAs de aprendizagem profundas são formadas. As redes neurais com multicamadas profundas *Feed-Forward* (*Deep Feed-Forward* - DFF) são caracterizadas pela presença de várias camadas ocultas, compostas por certa quantidade de *perceptrons*, capazes de aproximar, com precisão aceitável, uma função arbitrária. A função destas

camadas ocultas de neurônios é intervir entre a entrada externa e a saída da rede, permitindo a extração de estatísticas de alta ordem (PATEL & JHA, 2014). Elas podem aprender recursos cada vez mais complexos em cada camada (GOODFELLOW, et al. 2016).

Algoritmos de aprendizagem profunda DFF são construídos com camadas conectadas e fornecem precisão em muitas tarefas. As camadas próximas às entradas podem aprender a detectar determinadas particularidades, enquanto as camadas próximas à saída aprendem a juntar essas particularidades com outras partes diferentes. Essas partes podem ser utilizadas para diferenciar as sinapses.

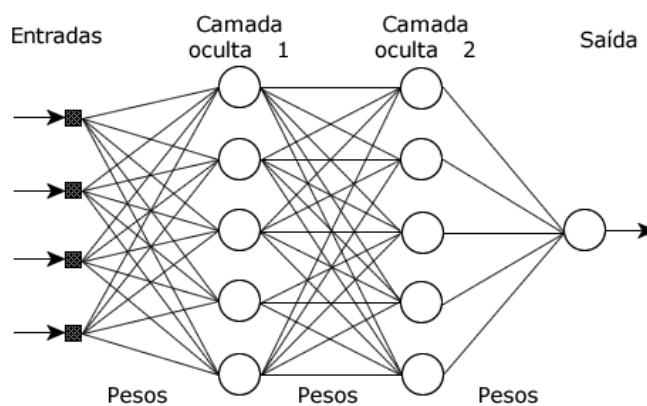
A Figura 7 a seguir, apresenta uma arquitetura de aprendizagem de máquina com múltiplas camadas ocultas do tipo *Feed-Forward* (DFF). Cada *perceptron* recebe sinais das variáveis de entrada e passam adiante uma versão ponderada e tratada desse sinal. Esses *Perceptrons* em paralelo formam uma camada oculta da RNA e passam a informação para a camada oculta seguinte e assim por diante, até a camada de saída.

A informação é passada através de cada camada por um processo não-linear, com a saída da camada anterior fornecendo entrada para a próxima camada. Cada camada é tipicamente um algoritmo simples. A primeira camada é a de entrada, enquanto a última é a de saída. Entre elas existem as camadas ocultas que não se conectam com o ambiente externo. Esse conjunto de *perceptrons*, que forma a rede, capta as informações relevantes fazendo um mapeamento de toda a informação e criando uma relação entre as entradas e saídas (RUNGTA, 2018).

O comportamento inteligente de uma RNA vem das interações entre as unidades de processamento da rede através de todas as camadas e o resultado estará na camada de saída, então, ela será capaz de reconhecer padrões e aprender consigo mesma. A informação se move da camada de entrada para as camadas ocultas, que processam os sinais e enviam o resultado para a camada de saída. Porém, se o valor de saída estiver longe do esperado, a rede neural atualiza os pesos e *bias* com base no erro, conhecido como processo de *backpropagation*. Com isso, os pesos e *bias* finais são usados para previsões (MANDIC and CHAMBERS, 2001). Este erro retroage

(*backpropagation*), ajustando os pesos de cada neurônio de cada camada (RUNGTA, 2018).

FIGURA 7 - Diagrama de uma Rede Neural Artificial (RNA) com múltiplas camadas (DFF).



Fonte: HAYKIN, 2001.

Modelos de redes neurais são especificados pela topologia da rede, características dos neurônios e regras de aprendizagem ou treinamento (MANDIC & CHAMBERS, 2001). Para Patel & Jha, (2014) a melhor arquitetura para uma RNA é a que fornece menor erro dentre as opções. A habilidade de aprender consigo mesma e melhorar seu desempenho fornece uma solução generalizada para aquele tipo de problema. O ajuste do erro corrige os pesos sinápticos através das funções de ativação, de modo que as saídas correspondam às entradas.

Conforme Goodfellow, et al. (2016), o grande desafio da análise é selecionar fatores de entrada adequados para os modelos de RNA. Como esta possui capacidade de aprendizado para modelos não-lineares, muitas variáveis de entrada podem ser usadas na rede, desde que haja amostras de treinamento suficientes. No entanto, como os tamanhos das amostras variam entre os diferentes locais de estudo, é importante limitar os fatores de entrada para que o tamanho da rede possa ser

mantido razoável para uma boa previsão. Por outro lado, se os fatores de entrada são selecionados de maneira muito estrita, ou seja, apenas os fatores altamente relacionados à saída são utilizados, a vantagem da modelagem da RNA comparada a uma regressão simples múltipla não seria significativa. O uso de níveis significativos para selecionar fatores relevantes como variáveis de entrada é importante no estabelecimento de modelos de RNA.

Segundo Haykin (2001), as RNAs possuem conexões não-lineares, mapeamento de entrada-saída e adaptabilidade dos pesos sinápticos às mudanças. Isso faz com que a rede possa fornecer resultados satisfatórios de acordo com a arquitetura dos neurônios artificiais, o que as tornam importantes no processamento de sinais e fornecem aprendizado e adaptação em função de dados.

A maior vantagem sobre os métodos convencionais é que elas não precisam de conhecimento minucioso sobre os mecanismos físicos do sistema que são descritos nas camadas de entrada e saída. Elas contam com alta taxa de acurácia para previsão de valores. Por meio de repetidas apresentações dos dados à rede, a RNA aprende padrões, procura as relações entre os dados e constrói modelos automaticamente. Para Haykin (2001) as RNAs não podem fornecer uma solução trabalhando individualmente, para isso, um problema complexo pode ser desdobrado e um subconjunto de tarefas pode ser repassado para se resolver.

Para tratar os dados e criar modelos inteligentes, é necessária uma etapa de preparação, que compreende a coleta e extração de dados, chamada engenharia de dados. Ela trabalha com a coleta, organização, preparação e armazenagem dos dados para que estes tenham bom nível de qualidade. Através dela, é possível identificar as melhores soluções de arquitetura para uma RNA.

Em seguida, toda a parte de tratamento de dados é feita pela ciência de dados, que faz a análise e interpretação dos dados já tratados pela engenharia de dados e usa os conhecimentos da matemática e estatística para modelagem. Através dela, é possível treinar os modelos de RNA buscando padrões que permitam o aprendizado, como veremos a seguir.

2.4.3. Ajuste de Hiperparâmetros

As entradas da RNA para previsão do conforto térmico correspondem às entradas do modelo de Fanger, que são as variáveis humanas e as variáveis ambientais. Se o erro for maior que a tolerância desejada, os pesos de conexão e as polarizações da RNA são ajustados na direção que diminui o erro. A fim de produzir o erro mínimo, um algoritmo baseado em gradiente descendente é geralmente implementado para adaptar todos os pesos e vieses. Esse método é normalmente chamado de método de retropropagação. Os pesos e vieses da RNA devem ser ajustados até fornecer um resultado confiável, ou seja, dentro de um erro tolerável.

Para isso, há uma vasta quantidade de RNAs, em que cada arquitetura é projetada para executar uma determinada tarefa. Assim, é preciso decidir a arquitetura geral da RNA através da quantidade de camadas ocultas e o número de neurônios em cada uma. Variar o número de neurônios ativos permite que um modelo controle a dimensionalidade efetiva da representação para uma determinada entrada (GLOROT et al., 2011).

Segundo Stathakis (2009), a topologia ideal pode ser alcançada por: tentativa e erro (fazendo vários experimentos e avaliando o melhor), pesquisa heurística (método de investigação baseado na aproximação progressiva de um dado problema), pesquisa exaustiva (enumera todas as possíveis soluções semelhantes e verifica se elas satisfazem o problema) ou algoritmos de poda (visam conceber uma estrutura de rede eficiente removendo pesos de forma incremental em uma rede).

Para encontrar o modelo mais apropriado é necessário compreender como a RNA funciona e como se ajusta os hiperparâmetros, para assim, usar corretamente o algoritmo de treinamento. Desta forma, será possível resolver problemas com mais eficiência.

Conforme Géron (2019), a topologia da rede é ditada pela escolha dos hiperparâmetros, e estes, vão determinar o tempo de processamento e o esforço computacional despendido no treinamento. Embora, os números de camadas ocultas e quantidade de neurônios não sejam os únicos hiperparâmetros que serão ajustados

em uma RNA, outros também importantes, devem ser ajustados para oferecer a melhor opção, como: otimizador para conversão de uma função, taxa de aprendizado, função de ativação, tamanho do lote (*batch size*) e número de épocas (*epochs*).

É importante saber que uma mudança de algum hiperparâmetro pode implicar a necessidade de ajuste de outro. Como a configuração destes valores é experimental para os testes de modelagem, alguns requisitos são importantes para começar, antes dos testes de treinamento, durante a criação da estrutura e comportamento do modelo. Muitas vezes são testadas várias configurações até encontrar o melhor desempenho.

Um dos atributos que deve ser bem ajustado é a função de ativação, que pode ser linear ou não-linear, e define o valor de saída de cada neurônio, funcionando como sinapse neural. Elas aplicam funções matemáticas aos dados gerando respostas. Haykin (2001) explica as funções de ativação não lineares sigmóide, tangente hiperbólica e ReLU, a seguir.

Conforme Glorot et al., (2011), as funções – sigmóide e tangente hiperbólica (*tanh*) – possuem seus valores de saída limitados (0 a 1 no caso de sigmóide e -1 a 1 no caso da *tanh*). À medida que as funções saturam, a derivada torna-se próxima de zero. Portanto, não há gradiente para se propagar de volta pela rede, tornando difícil para o algoritmo de aprendizado continuar adaptando os pesos. Já a função de ativação ReLU (*Rectified Linear Units*) retorna valor zero ou positivo, e não possui valores negativos. Nessa função a inclinação é constante. Esta função recebe um valor, se for maior que zero o valor recebido retorna o próprio valor, e se o valor for menor que zero retorna o valor zero. Ela permite preservar muitas das propriedades que tornam os modelos lineares fáceis de otimizar com métodos baseados em gradientes. Ao mesmo tempo, tende a generalizar bem e tem sido uma boa opção para as RNAs.

Os métodos de otimização funcionam como método de atualização dos pesos e buscam minimizar a função de custo, também conhecida como função de perda (GÉRON, 2019). Esses métodos podem ser divididos em quatro classes de algoritmos: sem diferenciação, de 1ª ordem, de 2ª ordem ou empíricos, cada um possuindo diferentes estratégias de otimização.

Com base na saída calculada e na saída real, é calculada a função de custo que basicamente fornece o erro na saída calculada. Em seguida, as informações de saída são realimentadas para a rede neural e os pesos são ajustados até que a função de custo seja minimizada. À medida que o valor da função de custo resultante diminui, a saída calculada torna-se mais precisa.

O otimizador é usado para calcular a previsão dada pelo modelo em termos de generalização. Esta função calcula o desempenho do modelo através da perda causada por uma estimativa imprecisa, estabelecendo uma relação entre o grau de imprecisão e o grau de perda (PATTERSON and GIBSON, 2017). Esta tarefa será realizada por um algoritmo de retropropagação que calcula os gradientes e os passa para o algoritmo de otimização. Então, ele altera os parâmetros e pesos da rede neural de modo a chegar a uma saída desejada.

Existem alguns algoritmos de otimização capazes de encontrar soluções ótimas para uma ampla variedade de problemas, como por exemplo: gradiente descendente, otimização de momento, gradiente acelerado de *Nesterov*, *AdaGrad*, *RMSProp*, *Adam* e *NAdam*. Os três últimos são métodos de gradientes de otimização adaptativa.

Neste trabalho, usa-se o otimizador *NAdam* baseado no método do gradiente descendente que funciona por meio da minimização da função dada pela taxa de aprendizagem e pelo gradiente de custo (GÉRON, 2019). O otimizador *NAdam* é a junção do *Nesterov* e *Adam*.

Outro hiperparâmetro importante é a taxa de aprendizado (*learning rate*) que é usada como uma taxa de correção a cada época (*epochs*). Se for muito grande, implica na falta de convergência, e se for muito pequena, o tempo de treino será muito grande, uma vez que o algoritmo terá que passar por muitas iterações, demorando a convergir (LECUN et al., 2015).

A época descreve quantas vezes todo o conjunto de dados de treino será apresentado à rede. Caso o número de época seja muito pequeno, a rede pode encontrar dificuldades em assimilar padrões menos comuns nos dados e caso seja muito grande, pode ocorrer o *overfitting* (LECUN et al., 2015).

Segundo Géron (2019), a taxa de aprendizado ótima é cerca de metade da taxa máxima de aprendizado (acima da qual o algoritmo de treinamento diverge) e pode ser treinada para algumas centenas de iterações, começando com um valor muito baixo e podendo aumentar gradualmente. Geralmente, o número de iterações de treinamento não precisa ser ajustado: apenas usa-se a parada antecipada (*callback*). Como a taxa de aprendizado ideal é dependente de outros hiperparâmetros, especialmente do tamanho do lote (*batch size*) que corresponde ao número de padrões que são mostrados à rede antes dos pesos serem atualizados, quando se modifica qualquer hiperparâmetro, deve-se atualizar a taxa de aprendizado.

É comum utilizar a potência de dois (2^n) para o *batch size*, mas outros valores podem ser usados (GÉRON, 2019). Segundo o autor, o tamanho do lote pode ter um impacto significativo no desempenho e no tempo de treinamento do modelo. O principal benefício de usar lotes grandes é que aceleradores de hardware, como GPUs (Unidade de Processamento Gráfico: *Graphics Processing Unit*), podem processá-los com eficiência, de modo que o algoritmo de treinamento verá mais instâncias por segundo. Porém, há um problema: na prática, lotes grandes geralmente levam a instabilidades de treinamento, especialmente no início do treinamento, e o modelo resultante pode não generalizar tão bem quanto um modelo treinado com um tamanho de lote pequeno. No entanto, ele afirma que é possível usar tamanhos de lote muito grandes (até 8.192) iniciando o treino com uma pequena taxa de aprendizado e ir aumentando. Isso leva a um tempo de treinamento muito curto, sem nenhuma lacuna de generalização. Porém, se o treinamento for instável ou o desempenho final for decepcionante, o tamanho do lote deve ser pequeno.

Após a especificação da arquitetura da RNA, é necessário definir o algoritmo de treinamento da rede em que os pesos sinápticos da rede são repetitivamente atualizados para minimizar o erro. Estatisticamente, o treinamento da rede serve para estimar os pesos, conforme Long, et al. (1990).

Para Géron (2019), usar com proveito as RNAs, significa que os modelos devem ser treinados para a previsão através da determinação dos hiperparâmetros da RNA, bem como camadas ocultas, número de nós, iterações e funções de treinamento; e os testes de validação devem garantir a precisão do modelo de forma a estimar a

generalização do modelo, ou seja, verificar como ele se comporta com novas entradas que não estão nos dados de treinamento.

2.4.4. Verificando o Desempenho da RNA

Para avaliar a qualidade do modelo e saber se ele generaliza bem para novos casos é preciso testá-lo. Os dados são divididos em dois conjuntos: de treinamento (calibração) e de teste (validação). O modelo é colocado em produção e seu desempenho monitorado para verificar se é confiável para novos dados (GÉRON, 2019).

No particionamento de dados, conforme a IBM (2016), a amostra de teste é uma amostra independente utilizada para rastrear erros durante o treinamento, ou evitar o excesso de treinamento (overfitting). É importante criar uma amostra de teste para avaliar a eficiência da RNA.

Fausett (2006) explica que os parâmetros são selecionados, de forma aleatória, para realizar o ajuste comparando os valores observados e os estimados pelo modelo. A otimização de um indicador estatístico usa o erro para este ajuste. Durante esse processo, a faixa de valores para os parâmetros é restrita para garantir o ajuste do parâmetro (KOVÁCS, 2006).

A RNA passa pelo processo de treinamento, onde uma porcentagem dos dados, separados para esta fase, são introduzidos no modelo e com isso a rede vai aprender a correlacionar os dados de entrada com os de saída através de um processo iterativo de ajustes aplicado a seus pesos para obter soluções adequadas sobre o que se quer resolver (PÁDUA BRAGA et al. 2007). Os pesos podem ser atualizados com base em uma medida estatística padrão de avaliação do erro, como por exemplo, a média do erro absoluto (*mean absolute error*: MAE) ou alguma outra, e o aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas, ou seja, quando se pode produzir saídas adequadas para entradas que não estavam presentes na etapa de treinamento.

Durante o treinamento, o modelo calcula o gradiente para atualizar o peso e o viés e exibir o resultado. Os dados são divididos em amostras e os neurônios irão competir a cada nova iteração do conjunto de treinamento. Assim, sempre que é apresentada uma entrada qualquer, existe uma competição entre os neurônios da camada de saída para representar a entrada naquele momento. Essas modificações sucessivas nos pesos dos neurônios representam o aprendizado quando ocorre o reconhecimento de todas as entradas apresentadas durante a fase de treinamento. Havendo pelo menos um neurônio que represente um estímulo apresentado na entrada, sempre que este estímulo for apresentado a esta rede neural, aquele neurônio que foi treinado para representá-lo, automaticamente irá ser disparado (LECUN et al., 2015).

Quando acabar o processo de atualização dos pesos, uma nova amostra é introduzida e ela será multiplicada pelos pesos já atualizados (HAYKIN, 2001). O aprendizado é este processo de atualizar os pesos. Os algoritmos de otimização devem resultar na melhor estimativa do erro. Desse modo, um conjunto de pontos otimizados é gerado, servindo como dados de teste para a RNA.

Segundo Haykin (2001), um algoritmo pouco flexível fornece um erro de predição alto na amostra de treino e à medida que sua complexidade aumenta, o erro de treinamento tende a diminuir. Entretanto, essa melhora aparente vem acompanhada da redução na capacidade de generalizar a informação, ou seja, com a chegada de novos exemplos (amostra de validação), o desempenho pode não ser satisfatório. Por isso, é preciso encontrar uma melhor configuração entre o modelo simples (que aprendeu pouco) e o modelo complexo (que aprendeu muito) para que com novos dados, o erro seja mínimo.

O objetivo do processo de aprendizado é apresentar pares de entrada e saída que quando acoplados com uma metodologia, que corrige a cada interação os pesos interconectados, produza um conjunto final de pesos que minimize o erro global. O treinamento é interrompido quando a rede apresenta boa capacidade de generalização e quando a taxa de erro for menor que o erro admissível (HAYKIN, 2001).

Após calibrada, a rede passará pela etapa de teste (calibração). O conjunto de dados que não foi utilizado no treinamento será empregado para validar o modelo. Nesta

etapa, é introduzido apenas os dados de entrada e solicitado que a rede retorne com os dados de saída estimados. Em seguida, é realizado um comparativo entre os dados observados e os estimados pela rede, então é calculado o erro, fazendo a diferença entre os dados observados e estimados para analisar se a rede apresenta resultados satisfatórios do fenômeno estudado (HAYKIN, 2001).

A amostra de validação é outro conjunto independente de registros de dados usados para avaliar a RNA final, conforme Géron (2019). O erro entre o real e o estimado fornece uma estimativa da capacidade preditiva do modelo.

Conforme Nguyen et al. (2021), muitos pesquisadores propuseram uma proporção de treinamento e teste (%) que variou de 70/30, 80/20 e 90/10 para solucionar vários problemas em relação aos estudos de estimativa da resistência residual do solo obtendo dados confiáveis. Usando a proporção de 30% a 80% constatou-se que o aumento no tamanho do conjunto de dados de treinamento melhorou o desempenho do treinamento e tornou o modelo mais estável. No entanto, quando o tamanho do treinamento aumentou de 80% para 90%, a tendência oposta foi encontrada no desempenho dos testes. Com base na análise estatística, uma razão de 70/30 para conjuntos de dados de treinamento e teste foi considerada uma boa razão para treinamento e validação dos modelos. Esse valor está de acordo com outros trabalhos verificados pelos autores que investigaram diferentes proporções de treinamento/teste para treinamento e validação de vários modelos de *machine learning* e previsão espacial de deslizamentos de terra como a melhor relação de treinamento/teste para obter o melhor desempenho.

Desta forma, o desenvolvimento de uma RNA passa pela calibração (conjunto de treinamento) e pela validação (conjunto de teste). Isto significa que na calibração se ajusta os parâmetros observados e na validação avalia-se o desempenho do modelo em outras situações novas para a rede. Comparando-se estatisticamente um conjunto de dados observados ao conjunto correspondente de dados estimados mede-se a semelhança entre os dois através do erro. Na calibração se ajusta os parâmetros do modelo para se obter o maior grau de semelhança possível e na validação verifica-se o quanto o modelo é confiável e coerente com a realidade (LECUN, 2015).

Com os resultados estimados e observados, é possível medir a acurácia do algoritmo, ou seja, a proporção de resultados corretos que o classificador alcançou.

2.4.4.1. Critério de Avaliação de Desempenho

As funções de perda são caracterizadas pelo erro de previsão do modelo e valores mais baixos representam melhor precisão do modelo. As medidas estatísticas padrão: raiz do erro quadrático médio (RMSE: *Root Mean Square Error*) e erro médio absoluto (MAE: *Mean Absolute Error*), são usadas para comparar e validar o desempenho dos modelos de *machine learning*. Em geral, RMSE é a diferença quadrática média entre os valores estimados e reais, enquanto MAE é a amplitude média dos erros. Valores mais baixos de RMSE e MAE significam maior capacidade de predição dos modelos.

A medida de desempenho mais comum de um modelo de regressão é a raiz do erro quadrático médio (RMSE). Portanto, para treinar um modelo de regressão linear, é preciso encontrar o valor de viés que minimize o RMSE. Porém, é mais simples minimizar o erro quadrático médio (MAE) do que o RMSE, o que leva ao mesmo resultado, porque o valor que minimiza uma função também minimiza sua raiz quadrada (GÉRON, 2019).

A escolha da função de perda vai depender da análise. Neste trabalho será usado o erro MAE (*Mean Absolute Error*), expresso na Eq. 1, em que n representa a quantidade de valores observados. A saída estimada (E_i) é comparada com a resposta observada (O_i) e o erro calculado. Seu valor representa o desvio médio entre dados Observados (O_i) e Estimados (E_i), sendo menos sensível a valores extremos. Ele dá um peso igual a todos os desvios. Quanto mais próximo de zero, menor a dispersão e melhor o modelo.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |E_i - O_i| \quad \text{Eq. 1}$$

O processo de minimização do erro, não tem convergência garantida e não possui um critério de parada bem definido (LECUN et al., 2015). Um critério de parada não recomendável, por não levar em conta o estado do processo iterativo de treinamento, é interromper o treinamento após um número fixo (definido previamente) de iterações, enquanto um critério de parada útil é a avaliação da capacidade de generalização da rede após cada época de treinamento. O processo de treinamento é interrompido antes que a capacidade de generalização da rede seja deteriorada.

Além disso, uma regressão entre os valores observados e estimados é um excelente critério de avaliação de desempenho da RNA. O coeficiente de correlação (R) e o coeficiente de determinação (R^2) representam a medida estatística de quão próximos os dados estão da linha de regressão ajustada, e foram utilizados neste trabalho, juntamente com o erro MAE.

Assim, R é empregado para avaliar a correlação dos valores previstos e reais da variável medida. Os valores de R estão entre -1 e +1, onde os valores absolutos de R próximo de 1 significam maior capacidade de previsão.

2.4.4.2. Validação

Esta é a etapa de avaliação do modelo em que se testa seu desempenho para novas situações através dos indicadores estatísticos. Uma forma de avaliar o quanto o modelo erra na hora de fazer regressão, classificação ou agrupamento de novos dados (de PÁDUA BRAGA, et al. 2007).

Uma forma de avaliar o modelo é pela comparação do erro obtido na calibração com o valor obtido na validação. Geralmente, o da validação será maior que o da calibração, mas se for muito maior, poderá significar que a calibração não foi significativa.

Para verificar o desempenho do modelo usa-se, juntamente com o MAE, uma regressão entre os valores estimados e observados.

2.4.5. *Overfitting* e *Underfitting*

Sobre os ajustes do modelo ao conjunto de dados, Dietterich (1995) explica que existem dois problemas que podem acontecer com o algoritmo: *overfitting* e *underfitting*.

No sobreajuste (*overfitting*), o modelo tem um bom desempenho nos dados de treinamento, mas não generaliza bem, ou seja, é ineficaz com novos dados. O ruído nos dados de treinamento não faz parte de um novo conjunto de dados.

Uma solução para o *overfitting* é reduzir o número de parâmetros nos dados de treinamento reduzindo o ruído nos dados ou otimizar o *dropout*. Esse parâmetro pode ser entendido como uma probabilidade de um neurônio de ter seu valor zerado naquela iteração, com o objetivo de que a rede fique melhor em generalizações (SRIVASTAVA, et al., 2014).

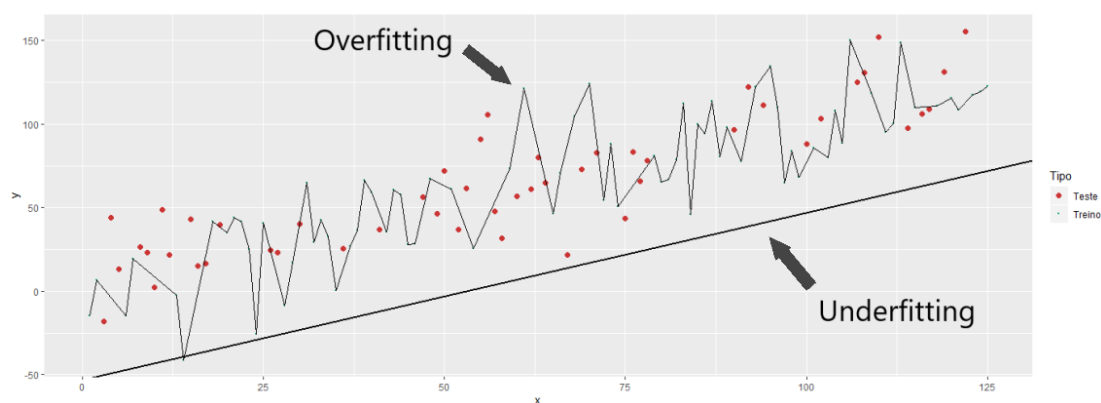
A técnica da regularização aplicada durante o aprendizado pode ser controlada por um hiperparâmetro. Ele deve ser definido antes do treino e permanece constante durante o treino. Se tiver um valor muito grande, obterá um modelo quase plano (uma inclinação próxima a zero) e o algoritmo de aprendizado quase certamente não se ajustará aos dados de treinamento, mas será menos provável que encontre uma boa solução. Ajustar hiperparâmetros é uma parte importante da construção de um sistema de *machine learning* (GÉRON, 2019).

No superajuste (*underfitting*), Dietterich (1995) explica que o algoritmo não possui parâmetros suficientes para a análise ou quando tenta ajustar um modelo linear às variáveis não-lineares há perda de tendência nos dados, não podendo ser generalizado para novos dados. A validação vai tentar verificar se esses problemas estão acontecendo e encontrar o meio-termo no qual os ajustes sejam suficientes.

Segundo Géron (2019) as opções para corrigir este problema são: selecionar um modelo com mais parâmetros, alimentar recursos melhores para o algoritmo de aprendizado e reduzir as restrições do modelo (por exemplo, reduzindo o hiperparâmetro de regularização).

Conforme Goodfellow, et al. (2016) exemplifica na Figura 8 abaixo, usar poucos neurônios nas camadas ocultas poderá resultar em *underfitting*, ou seja, pela insuficiência de neurônios pode haver perda de informação e o desempenho do modelo será ruim já que não consegue encontrar relações entre as variáveis. Enquanto usar muitos neurônios nas camadas ocultas pode resultar em *overfitting*, ou seja, a rede tem tanta capacidade de processamento de informações que o modelo tem um desempenho excelente, porém com os dados de teste o resultado é ruim, a rede não generaliza tão bem para novos dados.

Figura 8- Exemplo de *overfitting* e *underfitting*.



Fonte: Goodfellow, et al. (2016).

2.4.6. Aplicações das RNAs

As pesquisas sobre Inteligência Artificial e aprendizado de máquina não acontecem só na área acadêmica. Muitas empresas, indústrias e *startups* têm desenvolvido algoritmos para a solução de problemas do dia-a-dia e para melhorar processos em diversas áreas: medicina, saúde humana e animal, agronegócio, transportes, economia, finanças, comércio, *marketing*, telecomunicações, meteorologia, bioinformática, entre outras. Muitas ideias vêm se transformando em negócio, conquistando mercados e transformando a vida de muitas pessoas através de sistemas

automatizados que conseguem processar grande quantidade de informação e atender à expectativa dos usuários, seja apoiando ou tomando decisões, seja cumprindo tarefas cotidianas.

A IBM desenvolveu o Dr. *Watson* que a partir dos registros de saúde diários de um indivíduo, medidos por sensores que controlam seus dados biométricos e podem ser conectados com dados climáticos, faz uma busca no seu histórico ou de outros indivíduos com sintomas semelhantes e, assim, fornece um diagnóstico mais preciso, com a melhor opção de tratamento para aquele problema de saúde apresentado. Este conhecimento vai possibilitar ampliar a capacidade de atendimento, tratamento e prevenção de diversas doenças.

Em um futuro próximo, um algoritmo de Inteligência Artificial poderá executar muitas atividades profissionais tão bem quanto uma pessoa, pois a máquina será alimentada por dados de experiências anteriores e sua resposta será eficiente e livre de questões pessoais.

O maior problema é que à medida que o volume e a velocidade de alimentação de dados aumentam fica difícil interpretar grande quantidade de dados com eficiência. Para isso, é necessário diminuir a probabilidade de erros e aumentar sua acurácia, usando métodos de mineração de dados para extrair informações úteis a partir de grandes volumes de dados, encontrar relações ocultas, padrões válidos e regras para correlacioná-los de forma compreensível, auxiliando em decisões rápidas e de confiança (GALVÃO e MARIN, 2009).

Muitas pesquisas têm sido desenvolvidas aplicando RNAs de diversas arquiteturas aos mais diferentes bancos de dados.

Moustris et al. (2010) usaram modelos de Rede Neural Artificial (RNA) para prever o número total semanal de Admissão por Asma Infantil (CAA) na área de Atenas, na Grécia. Foram utilizados dados meteorológicos do Observatório Nacional de Atenas, dados de poluição do ar ambiente de sete áreas diferentes para o período 2001-2004 e registros hospitalares, de chegada de crianças com asma, dos três principais hospitais infantis de Atenas. Três modelos diferentes de RNA foram desenvolvidos e treinados

para prever a CAA para os subgrupos de 0 a 4, 5 a 14 e 0 a 14 anos. Os resultados mostraram que as RNAs podem fornecer uma previsão adequada do número total semanal de CAA em relação às condições bioclimáticas e de poluição do ar. Os números previstos estão em muito boa concordância com os números reais totais semanais observados da CAA.

A exploração agropecuária sofreu grandes avanços tecnológicos com o uso das RNAs. Pandorfi et al. (2011) avaliaram a precisão das RNAs para prever índices zootécnicos do rebanho suíno através do controle das variáveis térmicas e fisiológicas das porcas gestantes. Estudos na área agropecuária encontraram grande potencial de aplicação de RNAs para prever o comportamento do rebanho, adequação do manejo e monitoramento das atividades com base nas características climáticas associadas à resposta fisiológica baseada no desempenho do processo. As previsões permitem simular os dados de nascimento validados com dados reais com o intuito de modelar matematicamente a resposta dos animais ao ambiente de criação permitindo configurar as melhores características climáticas que mantêm menor estresse térmico e maior bem-estar animal.

Franco, et al. (2014) criaram um controle para automatizar uma residência energeticamente eficiente usando técnicas de Inteligência Artificial, especificamente RNAs, para abertura e fechamento de portas e janelas com o intuito de estabelecer conforto térmico dentro da residência, sem a necessidade de resfriadores ou aquecedores.

A previsão climática no campo da precipitação é sempre complicada, uma vez que existe grande variabilidade temporal e espacial nos dados de precipitação pluviométrica. Os estudos realizados por Anochi e Velho (2016) usando RNAs para previsão mensal e sazonal na região Sul do Brasil buscaram prever qual a melhor otimização de parâmetros de arquitetura das redes testando várias topologias diferentes até se obter resultados satisfatórios. A grande contribuição foi o uso de um método de redução de dados, aplicado no estudo de padrões climáticos mensais e sazonais, usando a teoria dos conjuntos aproximativos com redução de dados e Redes Neurais na derivação de modelos de previsão, a fim de realizar a previsão de precipitação. Assim, a técnica de mineração de dados, chamada de Teoria dos

Conjuntos Aproximativos (TCA) aplicada no processo de redução de dimensionalidade de dados, permitiu a identificação de informações relevantes presentes nos dados para a previsão do climática.

Algumas regiões passam por problemas com longo período de estiagem e esvaziamento dos reservatórios de água comprometendo o sistema de abastecimento municipal. Muitos estudos para reverter esse quadro e orientar o planejamento hídrico têm sido feitos para evitar o desabastecimento das cidades. Evangelista (2019) usou RNAs para prever a quantidade e o período de chuva na região dos Sertões de Crateús no Estado do Ceará e avaliou a previsibilidade do regime pluviométrico da região a partir da variabilidade da Temperatura de Superfície do Mar (TSM).

Junior, et al. (2020) mostraram como redes neurais recorrentes podem ser usadas na área da saúde compilando artigos de 2011 a 2020 nas bases *Scopus*, *Science Direct*, *PubMed*, *IEEE Xplore* e *Google Scholar* usando a sintaxe “*Recursive Neural Network*” e “*Human Movement*”. Eles concluíram que são enormes as possibilidades de aplicação das RNAs nos mais diferentes contextos, no caso, em relação à análise do movimento humano, podendo ser aplicadas às mais diversas formas de tratamento de dados.

Conforme visto, várias áreas utilizam as RNAs para analisar dados. Estudos na área da Climatologia Urbana, especificamente, do conforto térmico têm sido feitos. Porém, a grande maioria são sobre conforto térmico em edificações, e poucos estudos foram realizados em espaços abertos. Isso mostra a necessidade de avaliar a ferramenta de RNA em ambientes abertos para conforto térmico urbano.

Atthajariyakul & Leephakpreeda (2005) apresentaram um estudo para determinar o conforto térmico individual através da computação neural. O modelo de rede neural *Perceptron* Multicamadas (MLP) permitiu a determinação em tempo real do índice de conforto térmico: Voto Médio Previsto (PMV). O modelo de rede neural *Feed-Forward* foi proposto como uma função explícita da relação do índice PMV com as variáveis: temperatura do ar, temperatura do bulbo úmido, temperatura do globo, velocidade do ar, isolamento de roupas e atividade humana. Foi realizado um

experimento em uma sala com ar condicionado para demonstrar a eficácia da metodologia proposta e o controle do ar para manter o conforto térmico. Os resultados mostram boa concordância entre o índice de conforto térmico calculado a partir do modelo de rede neural em tempo real e o calculado a partir do modelo convencional de PMV.

Liu et al. (2007) apresentaram um modelo de avaliação do conforto térmico individual dentro das construções baseado em rede neural com aplicação da rede na criação de um microambiente com controle do ar condicionado. A avaliação do modelo mostrou boa correspondência com a sensação térmica real do indivíduo, o que indicou que o modelo pode ser usado para avaliar corretamente o conforto térmico individual.

Torres & Martin (2008) estudaram o índice de conforto, Voto Médio Previsto (PMV), para medir a eficiência do trabalho dos usuários em ambientes internos de edifícios. Eles propuseram um esquema de controle que mostra a capacidade das redes neurais, com base em um algoritmo de retropropagação, para modificar as condições ambientais de um espaço interno fechado, mantendo-o dentro do limite ideal de conforto, considerando não apenas as variáveis climáticas internas, mas também a atividade do indivíduo e o vestuário dos usuários do espaço. Várias simulações foram realizadas com o objetivo de estudar o comportamento e o desempenho do controlador proposto. A primeira experiência implicou manter constante o nível de atividade dos usuários e índices de isolamento de roupas e observar o comportamento do índice de PMV para cada controlador. No segundo experimento, os níveis de atividade dos usuários e seus índices de isolamento de roupas mudaram dia a dia. Os resultados puderam ajudar a controlar a temperatura do ambiente para manter os usuários sempre confortáveis.

Mirzaei et al. (2015) desenvolveram um modelo preditivo usando o conceito de RNA para controlar a temperatura do ar no interior de mais de 50 prédios localizados na ilha de Montreal (Canadá) a partir dos dados de massa térmica da vizinhança. Essa técnica treina um modelo único para a cidade, englobando as características únicas das sub-regiões que contêm edifícios em estudo. A análise das áreas radiais circundantes dentro de um intervalo permitiu à rede prever efetivamente futuras

condições internas resultantes de efeitos de Ilha de Calor Urbana (ICU) produzindo previsões horárias de temperatura interna a partir do Erro Médio Quadrático (MSE). Apesar dos bons resultados da técnica da RNA no estabelecimento da correlação entre o conjunto de dados de entrada e saída em relação às técnicas convencionais, como a regressão, a principal desvantagem da RNA foi sua alta dependência com o conjunto de treinamento. A saída do modelo fornece dados confiáveis, desde que a entrada esteja dentro da faixa de valores em que foi treinada. Essa desvantagem tornou-se evidente ao tentar prever temperaturas internas para os edifícios no centro de Montreal.

Segundo Ketterer and Matzarakis (2016), a rede neural pode ser usada para planejar o ambiente urbano usando mapas térmicos e um índice de conforto térmico conhecido por PET (Temperatura Fisiologicamente Equivalente). Os dados de entrada necessários para os modelos estatísticos foram dados meteorológicos em alta resolução, bem como dados sobre uso e cobertura do solo, incluindo dados morfológicos. Os dados meteorológicos foram obtidos através de transectos móveis em uma campanha de medição realizada em julho de 2014, em Stuttgart, na Alemanha. As abordagens estatísticas escolhidas para regressão linear múltipla passo a passo e RNA foram comparadas. O índice PET foi aplicado para analisar as condições térmicas humanas, levando em consideração o ambiente meteorológico e os parâmetros termofisiológicos. O modelo de RNA forneceu melhores resultados do que o modelo de regressão linear múltipla por etapas, resultando em um melhor ajuste do modelo.

Kariminia et al. (2016) investigaram o conforto térmico dos pedestres em duas praças de Isfahan, cidade no Irã, com base em dados demográficos e no papel do ambiente térmico. O objetivo principal foi prever uma série de índices úteis comuns, incluindo PMV, PET, SET (*Standard Effective Temperature*), TSV (*Thermal Sensation Vote*) e TMR (*Mean Radiant Temperature*) como saídas de um modelo não-linear da rede neural auto-regressiva com entrada exógena (NN-ARX). Os resultados foram comparados com a RNA e com o sistema de inferência Neuro-Fuzzy Adaptativo (ANFIS). Os resultados mostraram a superioridade do NN-ARX sobre a RNA e a ANFIS. Para o modelo NN-ARX, os indicadores estatísticos do erro quadrático

médio da raiz (RMSE) e do erro absoluto médio (MAE) foram de 0,53 e 0,36 para o PET, 1,28 e 0,71 para o PMV, 2,59 e 1,99 para o SET, 0,29 e 0,08 para o TSV e finalmente 0,19 e 0,04 para o TMR.

Silva (2017) estudou o conforto térmico para a cidade de João Pessoa (PB), localizada em clima quente e úmido e de baixa latitude. O objetivo de seu trabalho foi elaborar um Índice Ambiental Urbano (IAU) para definir a melhor relação entre as variáveis micrometeorológicas, a morfologia urbana e o conforto térmico urbano. Os valores das variáveis foram adquiridos através de pesquisas realizadas com medições *in loco* em espaços urbanos abertos. O estudo morfológico foi realizado por meio da identificação de um conjunto de indicadores urbanos relevantes a partir de um modelo de Sistema de Informação Geográfica (SIG). A distribuição espacial e a análise multivariada ajustaram e avaliaram os dados. A análise do conforto térmico em espaços abertos usou o programa de simulação ENVI-met para calcular a *Physiological Equivalent Temperature* (PET). Com os dados levantados, utilizou-se RNA para estimar os valores do índice PET e das variáveis microclimáticas no nível urbano. Foi elaborado um Índice Ambiental Urbano (IAU) através de análise multivariada: Análise de Componentes Principais (ACP) que foi aplicado às frações urbanas da cidade, e em simulação de cenários futuros a partir dos dados adquiridos com a projeção das variáveis microclimáticas. Os resultados obtidos demonstraram que as frações urbanas observadas não possibilitaram sensação de conforto durante o período estudado e o índice proposto evidenciou um distanciamento da relação adequada entre as variáveis morfológicas e as físicas, o que gerou ao usuário desconforto térmico. A contribuição deste estudo serve para subsidiar a tomada de decisão na escolha da melhor relação entre as prescrições urbanísticas e o conforto térmico de usuários em ambientes externos.

Moustris et al. (2018) tratam do desenvolvimento e aplicação de modelos de RNAs na cidade de Atenas (Grécia), durante um período de verão extremamente quente, para estimar os valores do índice de Temperatura Fisiologicamente Equivalente (PET) associado ao calor urbano e às condições de Ilha de Frescor Urbano (IFU) em vários aglomerados urbanos. Usando dados de temperatura do ar, umidade relativa, velocidade do vento e radiação solar (componentes de ondas curtas e longas) pode-se

comparar os valores horários de PET monitorados em campo, para vários aglomerados urbanos (ruas, praças e parques), com os valores fornecidos pelas RNAs. Para a avaliação da capacidade preditiva dos modelos de RNAs desenvolvidos, foram aplicados vários índices estatísticos de avaliação: viés médio dos erros, média quadrática do erro, coeficiente de concordância, coeficiente de determinação, taxa de predições verdadeiras, taxa de alarmes falsos e índice de sucessos. As RNAs apresentam boa capacidade de estimar valores de PET usando apenas valores por hora da temperatura do ar. Isso é importante nos casos em que as condições de conforto térmico e desconforto humano precisam ser analisadas e a única variável disponível é a temperatura do ar. Foram observadas limitações: o treinamento de RNAs requer, em geral, um grande número de séries temporais de dados meteorológicos. Além disso, no contexto de modelagem de cenários alternativos para lidar com opções de design dentro do tecido urbano para melhorar as condições térmicas, geralmente estes modelos não são facilmente interpretáveis. Os esforços futuros devem se concentrar em técnicas eficientes para manipular os resultados dos modelos de RNA a serem usados para interpretação de cenários modelados em problemas de ilhas de calor urbanas, tendo em mente as tendências de aquecimento durante o verão.

Mathew et al. (2019) estudaram o processo de formação de Ilha de Calor Urbano (ICU) em Chandigarh (Índia). Devido à rápida urbanização, as superfícies naturais da terra estão sendo substituídas por materiais antropogênicos que impactam negativamente o ecossistema. A Temperatura de Superfície (TS) foi usada para avaliar o efeito das ICU na cidade. Detecção remota de dados a partir dos sensores: *Moderate-Resolution Imaging Spectroradiometer* (MODIS) e *Advanced Spaceborne Thermal Emission and Reflection Radiometer Global Digital Elevation Model* (ASTER GDEM) têm sido utilizados para prever a Temperatura de Superfície (TS). No estudo, o modelo de regressão de vetores de suporte (*Support Vector Regression: SVR*) foi desenvolvido a partir dos valores de Temperatura de Superfície (TS) dos três anos anteriores, juntamente com o índice de vegetação aprimorado (EVI), a densidade da estrada (RD) e a elevação (E). Os resultados do modelo SVR foram validados usando os dados do ano de 2014. A Temperatura de Superfície (TS) foi

mais sensível ao RD. O modelo SVR foi comparado com RNA e mostrou a eficácia do modelo SVR para uma melhor previsão da Temperatura de Superfície (TS).

Yang et al. (2019) estudaram as Ilhas de Calor Urbanas (ICU) na cidade de Nanjing (China) e a partir de dados meteorológicos de rotina e em propriedades urbanas básicas usaram a equação de Theeuwes et al. (2017), formulada para países da Europa e comparada com a China, para estimar a ICU máxima diária. A medição de campo foi realizada com base no esquema da Zona Climática Local (LCZ), que é um protocolo de classificação padronizado para estudos de temperatura urbana. O conjunto de dados de temperatura de 658 dias coletados de seis classes diferentes de LCZ foi utilizado para o teste. Os resultados mostram que a equação diagnóstica produziu uma estimativa robusta e satisfatória da ICU máxima diária sob várias condições climáticas. O desempenho geral da equação para Nanjing, que possui um erro quadrático médio (RMSE) de $0,95^{\circ}\text{C}$ e um MAE de $0,60^{\circ}\text{C}$, aproxima-se muito do seu desempenho nas 14 cidades do noroeste da Europa (RMSE = $0,91^{\circ}\text{C}$, MAE = $0,58^{\circ}\text{C}$). Assim, a equação tem potencial para ser aplicável a outras cidades, devendo levar em consideração se o espaço é totalmente desenvolvido, misturado ou normal.

Lu et al. (2019) desenvolveram um modelo de conforto térmico com o banco de dados ASHRAE RP884 para três zonas climáticas com base no K-vizinho Mais Próximo (KNN), Floresta Aleatória (RF) e Máquina de Vetores de Suporte (SVM). Simularam um *Q-learning* para controle de temperatura com o modelo estatístico de conforto térmico com resultados de 49,3%, que supera o do PMV de 43% baseado na escala de sensação térmica de 7 pontos. Além disso, o controle de temperatura baseado em *Q-learning* pode atingir faixas de temperatura confortáveis com qualquer ponto de ajuste de temperatura inicial.

Chai et al. (2020) usaram algoritmos de aprendizado de máquina (ML) tais como, ANNs (*Artificial Neural Networks*) e SVM (*Support Vector Machines*), na previsão de TCV (Voto conforto térmico) e TSV (Voto Sensação Térmica) de ocupantes em residências com ventilação natural através de dados de pesquisa de campo na China com mais de 10.000 conjuntos de dados obtidos em levantamento de campo, dos quais 5.512 foram obtidos inteiramente em condições de ventilação natural. Os dados

foram separados e normalizados para usar a estatística para calcular o erro. A performance dos algoritmos ML foram, então, comparadas com os valores de PMV. Concluiu-se que o modelo ML (*Machine Learning*), especialmente ANNs foi confiável na previsão de TCV e TSV e teve um desempenho melhor do que os modelos tradicionais baseados em equilíbrio térmico. TSV foi mais eficaz e reflete melhor a condição de controle adaptativo dos ocupantes em edifícios residenciais ventilados naturalmente. PMV não tem um bom desempenho em edificações com ventilação natural.

Wang et al. (2020) se basearam no banco de dados ASHRAE *Global Thermal Comfort Database II* usando aprendizado de máquina para estudar quantas e quais métricas subjetivas devem ser usadas para a avaliação da experiência térmica. Eles comparam 6 diferentes algoritmos na previsão de preferência térmica: árvore de decisão, classificação de processos gaussianos, método de aumento de gradiente, máquina de vetor de suporte, floresta aleatória e regressão logística regularizada. O estudo mostrou que a métrica mais usada é a sensação térmica, seguida pela preferência térmica, conforto térmico e aceitabilidade térmica. Usou-se os métodos de regressão logística e Máquina de Vetor de Suporte (SVM) para prever a aceitabilidade térmica e preferência térmica com sensação térmica e conforto térmico e os dois métodos apresentaram precisão de predição semelhante. Na regressão logística os recursos e as formas de equação de regressão precisam ser especificados manualmente para representar o comportamento não-linear. Já a SVM não precisa especificar manualmente um formulário de regressão não linear, mas o limite de predição é mais irregular, mais sensível a anomalias e difícil de interpretar.

Luo et al. (2020) usaram diferentes algoritmos de aprendizado de máquina (ML) para determinar as melhores opções e métodos de processamento de dados para prever TSV (Voto Sensação Térmica) índice de conforto térmico usando o banco de dados ASHRAE *Global Thermal Comfort Database II*. Os modelos de ML geralmente têm maior acurácia na previsão de TSV. Especialmente, o método de Floresta Aleatória (RF) apresentou resultado de 63,6% de previsão para TSV com os recursos de temperatura do ar, umidade do ar e isolamento de roupas, sendo 2,6% menor do que se colocar todas as 12 variáveis de entrada. Foi abordado as soluções de ajuste de

parâmetros, divisão de dados de treinamento e teste e método de codificação, além de pacotes e códigos de programação em *Python* e *R*.

Note que as duas últimas pesquisas utilizaram o banco de dados *ASHRAE Global Thermal Comfort Database II*, seja para avaliar os melhores algoritmos de aprendizagem de máquina na avaliação do conforto térmico, seja para avaliar os parâmetros de entrada e a acurácia na previsão do conforto térmico. Com a análise destes trabalhos, foi possível direcionar os objetivos atuais de pesquisa de forma diferente do que já foi trabalhado, buscando uma nova abordagem do banco de dados.

Observou-se, a partir das pesquisas apresentadas acima, que Moustris et al. (2010), Ketterer & Matzarakis (2016), Kariminia et al. (2016), Silva (2017), Moustris et al. (2018), Mathew et al. (2019) e Yang et al. (2019) tiveram em comum o fato de terem desenvolvido suas pesquisas de conforto térmico em espaços abertos. Os demais pesquisadores fizeram suas análises no interior de edificações.

De maneira geral, nos trabalhos levantados, as análises de conforto térmico utilizando RNA foram validadas e as considerações foram satisfatórias em termos de desempenho das RNAs, embora tenham identificado limitações técnicas para treinamento da rede, a depender do tamanho da RNA, do tamanho da série temporal (banco de dados) e da disponibilidade computacional.

Apesar do uso crescente de RNAs e de suas vantagens (propriedades de generalização, capacidade de lidar com dados de alta dimensão e não linearidades), o número de aplicações de modelos de RNAs para problemas relacionados a aspectos bioclimáticos ainda é limitado, especialmente no caso do ambiente urbano. Alguns estudos já são feitos buscando padrões do microclima relacionados à formação de ICU e ao desconforto térmico.

3. MATERIAIS E MÉTODOS

Este capítulo descreve o processo utilizado para justificar a escolha da modelagem da RNA.

A Base de Dados usada foi a ASHRAE *Global Thermal Comfort Database II* da qual extraiu-se os dados que iriam alimentar a RNA. Todos os arquivos foram armazenados em uma planilha no *Google Drive* para depois ler o conjunto de dados de forma prática.

Inicialmente foi utilizada a plataforma *Google Collaboratory*, também conhecida por *Colab*, um ambiente de desenvolvimento gratuito na nuvem, baseado em *Jupyter notebooks*, um editor de código em *Python*, que conta com aceleração por GPU e integração fácil com o *Google Drive*. O *Colab* foi usado para experimentar a capacidade de generalização de uma RNA treinada com poucos valores e para avaliar sua performance.

Após esse teste, com um volume maior de dados, a RNA foi treinada no servidor da Casa Civil do Governo do Estado de Mato Grosso. O programa rodou no servidor virtual *PowerEdge R720*, tendo 200Gb de memória RAM e 32 núcleos de processamento, de modo a otimizar o tempo de processamento.

A seleção dos parâmetros e hiperparâmetros da RNA do tipo *Feed-Forward (FF)* e a separação dos dados de treinamento, dos dados de teste necessários para validação do processo foram realizadas em linguagem de programação *Python* usando as bibliotecas de *TensorFlow* e *Keras* disponíveis, para rodar os algoritmos. Assim, o processo de modelagem da RNA foi descrito.

3.1. LINGUAGEM DE COMPUTAÇÃO

Várias linguagens são usadas para escrever os códigos de *machine learning*. Neste trabalho usou-se uma linguagem de alto nível chamada *Python*, por possuir uma sintaxe simples. Toda a documentação sobre essa linguagem é encontrada na internet.

Esta linguagem é do tipo aberta (*open-source*) para pesquisa em plataforma online, de distribuição gratuita e traz vários dos pacotes e funcionalidades simplificadas, para rodar os códigos.

É possível trabalhar usando os pacotes específicos de *machine learning* para ler os arquivos requisitados para entrada e importar as bibliotecas para a análise do modelo de conforto térmico através de poucos comandos.

Posteriormente, o modelo foi disponibilizado na plataforma *online GitHub* de hospedagem de código-fonte e arquivos, em que se pode criar repositórios e hospedar projetos, colaborar com *softwares open source* e interagir com códigos de terceiros. O *GitHub* armazena os dados na nuvem (*cloud*), permitindo acessá-los pela internet.

Algumas bibliotecas usadas ao longo desta pesquisa foram: *TensorFlow*, *Keras*, *scikit-learn*, *Pandas*, *seaborn*, *numpy*, *time* e *matplotlib*.

O *TensorFlow* é uma biblioteca de código aberto para computação numérica, desenvolvida pela equipe do *Google Brain*, na organização de pesquisa *Machine Intelligence* do *Google*. A computação é distribuída, entre várias GPUs. Desde sua 2ª versão o *TensorFlow* incorporou o *Keras*, trazendo uma plataforma muito mais amigável (RUNGTA, 2018). Estas bibliotecas são muito usadas para *machine learning* e IA.

Segundo Géron (2019), a biblioteca *Keras* permite criar RNAs pois traz diversas funções que constroem partes fundamentais das redes neurais, como camadas, otimizadores, objetivos, entre outras. Inclui alguns dos algoritmos para otimizadores (*Adam*, *RMSProp*), normalização (*BatchNorm*) e camadas de ativação (*ReLU*, *ELU*, *LeakyReLU*).

Mais a frente serão apresentadas as bibliotecas e funções que foram usadas neste trabalho, na seção 3.4, desenvolvimento do modelo de RNA-FF.

3.2. BANCO DE DADOS ASHRAE

Os dados de pesquisas climatológicas realizadas em 28 países de todo o mundo, abrangendo países em desenvolvimento e desenvolvidos, foram agrupados pelo *Center for the Built Environment* (CBE) da Universidade da Califórnia no Centro de Berkeley e pelo *Indoor Environmental Quality Laboratory* (IEQLab) da Faculdade de Arquitetura da Universidade de Sydney. Todos os dados que puderam ser coletados, embora algumas pesquisas não puderam dispor de aparelhos para medir todos os parâmetros climáticos, foram compilados em um banco de dados aberto chamado *ASHRAE Global Thermal Comfort Database* que contou com a reunião de trabalhos de vários autores publicados em revistas internacionais. Em 1998 esta coletânea foi lançada em primeira versão, com dados desde 1985, a *ASHRAE Global Thermal Comfort Database I* e, em 2014, lançada a segunda versão (II), que foi atualizada em 2018.

Esta compilação forma um rico conjunto, inédito até então, para compor o banco de dados *ASHRAE Global Thermal Comfort Database*. Esse Banco de Dados serve como fonte de estudo e comparação de diversas regiões do mundo. A base de dados *ASHRAE Global Thermal Comfort Database II* é disponibilizada sob a *Open Database License*: <http://opendatacommons.org/licenses/odbl/1.0/>

O banco de dados *ASHRAE Global Thermal Comfort Database* é capaz de possibilitar o estudo de conforto térmico em todo o mundo e comparar com outras pesquisas na área para avaliar as diferenças ou similaridades das respostas, em que os pesquisadores podem, até criar um indicador de conforto térmico mundial.

Os dados usados são brutos em vez de dados processados, conforme observações de Wang et al. (2020). Os dados de campo foram coletados através da medição das variáveis climáticas e das respostas aos questionários sobre a percepção térmica em relação ao ambiente de análise, no período de 1985 a 2018. Estes dados foram levantados de 52 campos de estudo em 160 tipos diferentes de construções, para avaliação de métricas de conforto térmico.

Atualmente, conta com 107.583 registros no total, 25.616 do banco de dados I e 81.967 do banco de dados II. As pesquisas usaram condições reais ao invés de ambientes controlados.

A equipe de compilação de Földvary et al. (2018) conduziu uma validao final comparando cada conjunto de dados brutos com a publicao relacionada fornecida pelo contribuidor de dados para evitar erros de transmisso. Um controle de qualidade sistemtico de cada estudo foi realizado para garantir que os registros no banco de dados eram razoveis. Primeiramente, as distribues de cada varivel foram visualizadas para identificar valores aberrantes. Em seguida, grficos cruzados entre duas variveis (por exemplo, sensao trmica e conforto trmico) foram usados para verificar os dados codificados incorretamente. Finalmente, foi feito um processo de validao cruzada no qual algumas linhas de cada estudo foram selecionadas aleatoriamente para verificar a consistncia entre o conjunto de dados original e o banco de dados padronizado.

A anlise desse conjunto de dados usando ferramentas computacionais, como Redes Neurais Artificiais (RNA), ser usado para prever o conforto trmico em outras situaes que possam se utilizar desta modelagem.

3.2.1. Composio do Banco de Dados ASHRAE

No Banco de Dados de conforto trmico Global ASHRAE, usando os dados de estudo dos autores e obras,  possvel coletar as informaes de 68 atributos, sendo votos subjetivos de conforto trmico, caractersticas e tipos da construo, informaes demogrficas dos indivduos, clima do local, anlise de parmetros de conforto trmico e variveis meteorolgicas.

Estes dados oferecem uma oportunidade de avanar o conhecimento sobre conforto trmico em termos de aprendizado de mquina para abordar questes fundamentais que so facilitadas pelo processamento de um grande nmero de dados. Com o cdigo aberto, os resultados podem ser reproduzidos por qualquer pesquisador.

O conjunto de dados é fornecido como um arquivo de valores separados por vírgula (.csv). A primeira linha contém cabeçalhos de 68 variáveis. Cada linha representa as respostas do questionário de um indivíduo e as medidas instrumentais associadas, valores de índice térmico e observações meteorológicas externas, quando disponíveis.

No site <www.comfortdatabase.com> está o *ASHRAE Global Thermal Comfort Database II*. Na página do ASHRAE marca-se as opções de busca que se quer ou deixa sem marcar nada, para ter todas as opções.

Os dados são descarregados em um arquivo de texto, sendo que nas colunas estão listados os itens abaixo:

- Publicação
- Pesquisador
- Ano
- Estação (primavera, verão, outono, inverno)
- Grupo Climático de Köppen
- Clima (semi-árido frio, mediterrâneo fresco de verão, deserto quente, semi-árido quente, mediterrâneo quente de verão, subtropical úmido, continental quente-úmido de verão com monções, subtropical úmido influenciado pelas monções, oceânico, planalto subtropical, oceânico temperado, savana tropical seca, monção tropical, floresta tropical, savana tropical úmida, continental úmido de verão quente, mediterrâneo quente de verão)
- Cidade
- País
- Tipo de Construção (sala de aula, habitação multifamiliar, escritório, outras, centro sênior)

- Estratégia de resfriamento a nível de construção (ar-condicionado, ventilado mecanicamente, modo misto, naturalmente ventilado)
- Estratégia de operação de resfriamento
- Estratégia de aquecimento a nível de construção
- Idade
- Sexo (masculino, feminino)
- Sensação térmica (escala de 7 pontos)
- Aceitabilidade térmica (aceitável e inaceitável)
- Preferência térmica (frio, neutro e quente)
- Aceitabilidade de Movimentação do ar (aceitável e inaceitável)
- Preferência de Movimentação do ar (menos, nada de mudança ou mais)
- conforto térmico (escala de 3, 5 ou 7 pontos)
- PMV (escala de 3 pontos)
- PPD (0 a 100)
- Temperatura do ar (°C)
- Temperatura do ar (°F)
- SET (10 a 40)
- Índice de resistência da roupa (0 a 2,3 Clo)
- Taxa metabólica (atividade física em Met)
- Atividade 10 minutos
- Atividade 20 minutos

- Atividade 30 minutos
- Atividade 60 minutos
- Temperatura operativa (°C)
- Temperatura operativa (°F)
- Temperatura radiante (°C)
- Temperatura radiante (°F)
- Temperatura de globo (°C)
- Temperatura de globo (°F)
- Temperatura de globo (superior= 1,1m)
- Temperatura de globo (média= 0,6m)
- Temperatura de globo (inferior= 0,1m)
- Umidade relativa (%)
- Preferência de umidade relativa (mais seco, nada de mudança ou mais úmido)
- Sensação de umidade (-3 a 3)
- Velocidade do ar (m/s)
- Velocidade do ar (fpm)
- Velocidade do ar (superior= 1,1m)
- Velocidade do ar (média= 0,6m)
- Velocidade do ar (inferior= 0,1m)
- Altura da pessoa (cm)
- Peso da pessoa (kg)

- Cortinas em uso (fechada ou abrir)
- Ventilador em uso (ligado ou desligado)
- Janelas em uso (abrir ou fechar)
- Portas em uso (abrir ou fechar)
- Aquecedor em uso (ligado ou desligado)
- Temperatura do ar exterior mensal (°C)
- Temperatura do ar exterior mensal (°F)
- Banco de Dados ASHRAE (I ou II)

3.2.2. Alimentação da RNA com o Banco de Dados

As seguintes variáveis foram usadas para alimentar a entrada da rede neural: índice de resistência térmica das roupas (clo), taxa de metabolismo (met), temperatura do ar (°C), umidade relativa do ar (%), velocidade do ar (m/s) e temperatura mensal do ar externa (°C). Elas foram escolhidas porque estão presentes em quase todas as métricas de conforto térmico, conforme apresentado no item 2.4.2.

O pré-processamento de dados é um conjunto de técnicas de mineração de dados usadas para transformar dados brutos em formatos úteis e eficientes. Aqui entra o conhecimento de engenharia de dados, que consiste na preparação dos dados com: limpeza, transformação e redução dos dados.

Na etapa de limpeza de dados, serão verificados valores faltantes e outliers (dados que se diferenciam drasticamente de outros, fugindo da normalidade e apresentando-se fora da curva). Na transformação dos dados ocorre a normalização dos dados (para deixar os valores dentro de limites preestabelecidos) e seleção de atributos. A redução dos dados representa o conjunto de dados que restou para análise da modelagem.

A base de dados disponibilizada pela ASHRAE possuía no momento do estudo 107.583 registros compilados, mas com muitos campos ausentes nas suas diversas variáveis. Como os dados vieram de vários estudos independentes, cada parâmetro não incluiu necessariamente todos os registros. Onde faltavam dados, esse intervalo específico de células foi preenchido com um valor nulo.

A partir desta consideração, ao selecionar os parâmetros que iriam compor a RNA, foram descartadas as opções com valores nulos, uma vez que cruzando os valores, foi possível pegar o que tinha mais dados para fazer a análise. Com isso, apenas 58.654 registros completos foram selecionados para modelar a rede a partir dos parâmetros selecionados para entrada da rede neural, representando 50,8% do total.

A variável de conforto térmico usada para saída da rede neural foi a sensação térmica (*Thermal_Sensation*). Ela se justifica por ser a mais utilizada no banco de dados da ASHRAE de conforto térmico II, conforme estudos de Wang et al. (2020), devido à sua associação direta com medidas físicas (temperatura do ar, velocidade do ar e umidade relativa do ar), individuais (taxa de metabolismo e índice de resistência térmica da vestimenta) e modelos de PMV/PPD ou SET.

3.3. PARÂMETROS E HIPERPARÂMETROS DA REDE *FEED-FORWARD*

Este trabalho utiliza RNAs de aprendizado supervisionado, do tipo *Feed-Forward*. Alguns experimentos foram feitos ao longo desta pesquisa usando diferentes hiperparâmetros, a partir de experiências buscadas na literatura, para chegar em uma rede que fosse mais robusta e que generalizasse bem para outros dados. Então, a partir desses hiperparâmetros a rede foi modelada e treinada.

Os processamentos variaram de 1 dia a algumas semanas e foram feitos no servidor *PowerEdge R720* da Casa Civil do Estado de Mato Grosso. Todo o código desenvolvido foi disponibilizado em repositório público disponível via WEB¹, através de um *GitHub*, e pode ser acessada para seu detalhamento.

¹ https://github.com/demusis/pvmrna_ASHRAE

A precisão do modelo nos dados de teste a partir de um tamanho de lote deve ser avaliada juntamente com a taxa de aprendizagem para obter uma configuração adequada com o mínimo de gastos computacionais. Para o treinamento da rede torna-se importante calcular o menor erro e definir corretamente os otimizadores de aprendizado e atualização da função de ativação. O valor definido para a taxa de aprendizado precisa ser cuidadoso. Se for muito pequeno, o treinamento poderá ser lento e se for muito grande, poderá não compensar totalmente grandes tamanhos de lotes em conjuntos de dados mais complexos.

Todos os parâmetros e hiperparâmetros devem ser definidos com cautela e testadas as configurações para diminuir a incerteza quanto ao desempenho do modelo. Segue alguns requisitos que devem ser observados na programação:

- **Epochs** (quantidade de iterações ou número de ciclos do algoritmo de treinamento);
- **Batch size** (tamanho do lote ou número de exemplos de treinamento usados em uma iteração);
- **Validation train-test-split** (porcentagem de dados para o treinamento da rede);
- **Activation function** (introduz uma não-linearidade e repassa o resultado do neurônio adiante);
- **Weight** (velocidade de avanço das iterações que produz o disparo do sinal da sinapse);
- **Bias** (também chamado de viés, é a constante que determina quando se deve considerar ou melhorar a significância das somas dos pesos vezes as entradas);
- **Optimizer** (converge o modelo de acordo com o gradiente de iteração e o tamanho do passo para alcançar com melhor precisão o mínimo da função custo);

- **Função de custo** (também chamada função de perda, serve para avaliar os coeficientes do modelo calculando uma previsão para cada instância de treinamento no conjunto de dados e comparando as previsões com os valores de saída reais e calculando o erro médio);
- **Learning rate** (influencia a precisão final da classificação);
- **Arquitetura da Rede** (forma que será usada para a rede);
- **Número de camadas ocultas e**
- **Número de neurônios em cada camada.**

A configuração correta desses parâmetros pode impactar a capacidade de generalização da *deep learning* (PATTERSON and GIBSON, 2017). A seleção dos hiperparâmetros não é uma tarefa fácil, pois a quantidade de possibilidades escolhidas é alta e a avaliação das combinações possíveis pode ser grande.

Por uma questão de tempo e objetivo do trabalho, as tentativas foram limitadas a quatro para testar a melhor configuração de RNA. Cada execução demanda muito tempo e processamento, por esta razão, escolheu-se essa quantidade.

Neste trabalho, foram usadas as seguintes configurações:

- Número de *epochs*: 1500
- *Batch size*: 512
- Taxa de aprendizado: 0,01
- Função de ativação: *ReLU* para todas as camadas
- *Optimizer*: *Nadam*
- Arquitetura de Rede: *Feed-Forward* (FF)
- Porcentagem de treinamento/teste: 70:30

- Número de camadas ocultas: três (para garantir a não linearidade usou-se rede triangular)
- Número de neurônios por camada: variável com base em um modelo triangular

3.4. DESENVOLVIMENTO DO MODELO DE RNA-FF

O fluxograma do modelo de RNA é apresentado na Figura 9 e mostra toda a sequência desenvolvida na programação do modelo da RNA.

Este fluxograma serve para organizar o trabalho e mapear os processos e etapas de construção do modelo da RNA de forma mais prática e visual.

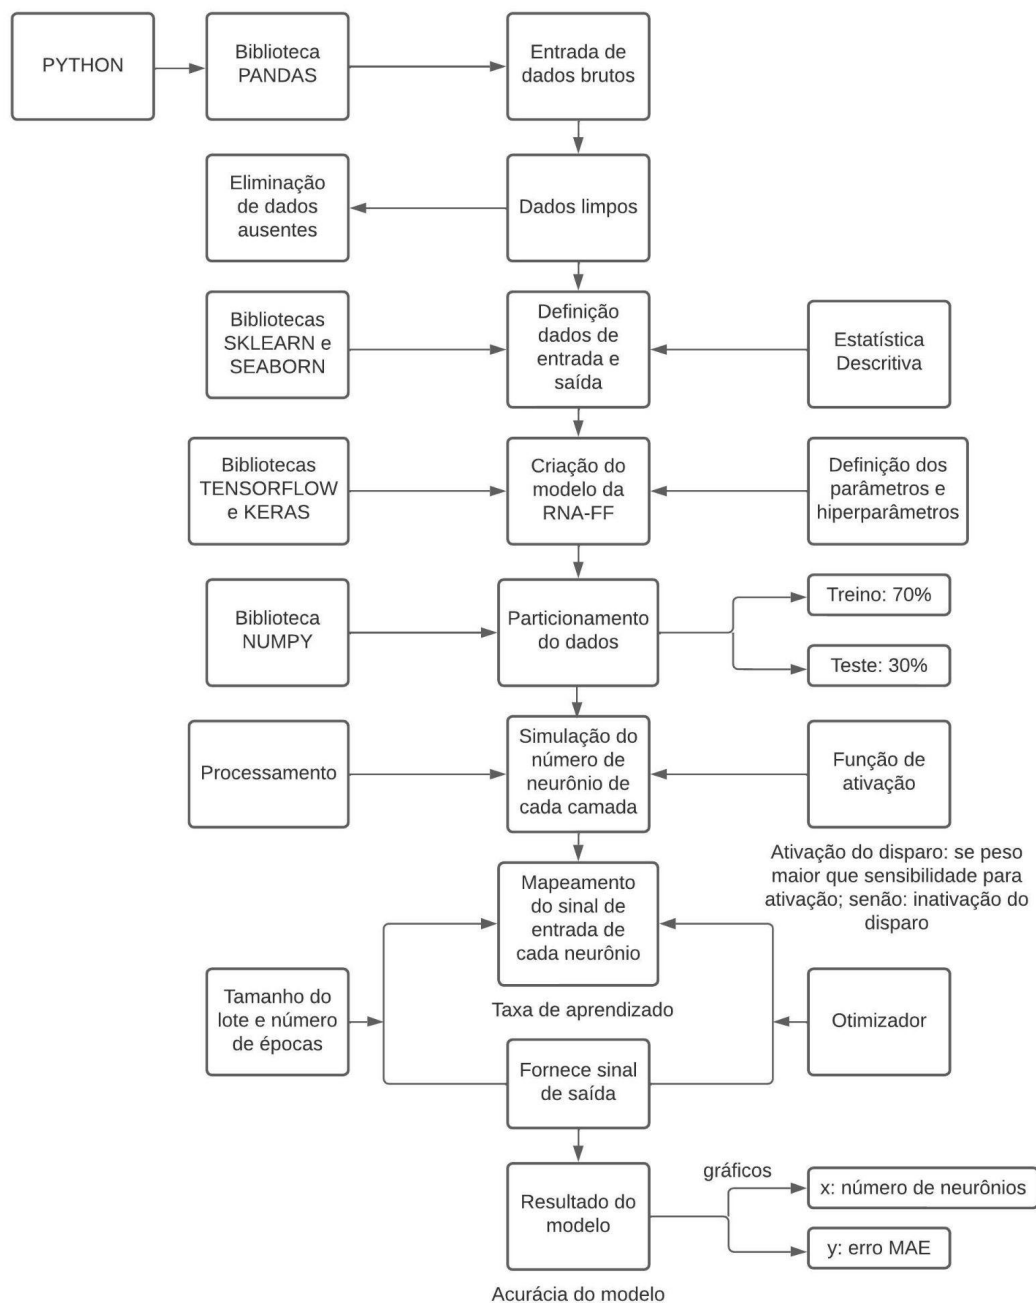
No presente trabalho foi usada a linguagem de programação *Python*, que utiliza uma comunidade online e suas bibliotecas para otimizar processos e tarefas. O código foi desenvolvido em *Python* - juntamente com a bibliotecas *Pandas*, *TensorFlow* e *Keras*, além de outras necessárias para o código e apresentadas a seguir.

Todos os comandos usados no código são apresentados e explicados de forma clara para facilitar o entendimento da modelagem da RNA que se encontra no GitHub.

O banco de dados ASHRAE é acessado pelo site e salvo no DRIVE em uma tabela no formato “.csv” e depois importado pelo *Python* para ser usado no programa.

A função “*perf_counter*” liga o cronômetro para marcar o tempo de processamento de cada simulação.

FIGURA 9 - Fluxograma do Modelo de RNA.



Fonte: autora.

Para a manipulação e análise de dados foi importada a biblioteca “*Pandas*” que oferece operações para manipular tabelas numéricas e séries temporais. Usando estatística descritiva pelo comando “*describe*” é gerada uma tabela fornecendo as estatísticas: “*count*”, “*mean*”, “*std*”, “*min*”, “25%”, “50%”, “75%” e “*max*”. Os dados com valores nulos são eliminados pelo comando “*dropna*”, com isso, a estatística “*count*” irá fornecer apenas dados que estejam preenchidos com algum valor. Neste sentido, os parâmetros que têm maior “*count*” serão considerados como de maior interesse para a simulação de conforto térmico: “*Clo*”, “*Met*”, “*Air Temperature C*”, “*Relative Humidity*”, “*Air Velocity ms*” & “*Outdoor Monthly Air Temperature C*” que correspondem à variável “*x*” e *Thermal Sensation* corresponde à variável dependente “*y*”. Esses parâmetros são, então, padronizados estatisticamente (normalizados) para convergir melhor, o que afeta o desempenho.

Outra biblioteca importada é a “*Sklearn*” que é um módulo de *machine learning* de código aberto usada para a programação da rede neural que inclui algoritmos de classificação, regressão e agrupamento. Além desta, outra biblioteca importada usada foi a “*Seaborn*” para visualização dos dados estatísticos baseada em “*matplotlib*” com uma interface atraente de alto nível.

Com a função “*pairplot*” cada parâmetro é cruzado com outro e a partir disso são visualizadas as correspondências na matriz de gráficos de dispersão e as relações encontradas entre elas.

Para a criação do modelo de rede neural usa-se *Tensorflow* utilizando a notação do *Keras* sendo mais fácil definir o modelo através deste último. Importa-se a função “*Layers*” para configurar as camadas de entrada, ocultas e de saída. Na camada de entrada são inseridos os valores de “*x*”, enquanto a camada de saída fornece o valor de “*y*”.

O método “*Train_Test_Split*” é projetado para dividir os dados em conjuntos de treinamento e validação aleatoriamente enquanto a função “*Shuffle*” embaralha os dados para evitar que a tendência nos dados colhidos direcione para algo específico e que não seja aplicável a qualquer dado. A calibração e o teste servem para verificar se os dados são bons o suficiente para serem usados.

A função “*Sequential*” adiciona cada camada em sequência sendo que a primeira camada recebe os dados de entrada do sistema e manda sua saída para a próxima camada, e a saída da última camada sendo a saída do modelo. No código foram usadas três (3) camadas para garantir a não linearidade e explicar melhor o comportamento da rede neural, conforme explicações de Stathakis (2009).

A função “*Dense*” parametriza a arquitetura da rede, no caso a quantidade de neurônios que haverá em cada camada, que foi escrita para ser um modelo triangular (HAQUE et al. 2018) com a quantidade de neurônios da primeira camada sendo o dobro da próxima camada e a segunda camada tendo o dobro da terceira. Se o valor não for inteiro, a função “*Round*” arredonda para cima.

Com a função “*Dropout*” de tempos em tempos vai na rede neural e mata um neurônio para que a rede não fique estacionada. Quando se retira um neurônio, ocorre uma melhora da rede (SRIVASTAVA et al., 2014).

A função “*Activation*” é a função de ativação “*ReLU*” (*Rectified Linear Unit*) que tem valor zero para valores negativos e cresce linearmente para valores positivos. Se o peso da função multiplicado pela entrada for maior que a sensibilidade imposta pela função de ativação, ocorre a ativação do disparo que passa a informação deste neurônio para o próximo. Se for menor que a sensibilidade imposta pela função de ativação, a informação fica inativa. As conexões entre os neurônios representam os pesos e regulam a influência de um neurônio em outro que ele pode interagir. Cada alteração nessas conexões pode mudar o desempenho da rede. Neste caso, foi usada a função *ReLU* para todas as camadas (GLOROT et al., 2011).

A função “*Optimizer*” é usada para atualizar os pesos da rede, que no caso, implementa o algoritmo “*NAdam*” (*Nesterov* mais *Adam*) que é o otimizador de treinamento “*Adam*” (*Adaptive Moment Estimation*) com impulso de “*Nesterov*” em vez de impulso normal. Ela calcula o gradiente do erro em relação aos pesos, multiplica pela taxa de aprendizado e subtrai dos erros (DOZAT, 2016).

Já o comando “*Compile*” configura o modelo, preparando-o para treinamento.

“*Loss*” é o tensor de perda que devolve o erro, no caso, do tipo “MAE” que possui dimensão igual à dimensão dos valores observados e preditos. Seu valor representa o desvio médio entre o Observado e o Estimado. Modelo com menor média do erro.

A biblioteca “*Numpy*” é especializada em ferramentas matemáticas para o cálculo de matrizes e *arrays* e realiza gráficos.

Daí, o comando “*Fit*” vai treinar a rede neural. Os dados de treino são separados em partes de mesmo tamanho e cada parte é usada para atualizar os pesos, depois é usada a próxima parte para atualizar novamente os dados até que todos os dados sejam varridos. A porcentagem de dados para treinamento da rede neural é definida em “*validation_split*”. Essa interação ocorre a quantidade de vezes dada por “*epochs*” e o tamanho desses lotes é dado por “*batch_size*”. Para não precisar escrever nada enquanto se faz esse processamento, “*verbose*” é igual a zero.

Função “*lambda*” é um comando para que cada linha processe o modelo e retorne o mínimo, na coluna “MAE”.

Variável “*resultados.append(df)*” vai guardar só o valor de “*n*” na variável “*x*” e o erro “MAE” na variável “*y*”. A linha com a função “*for aux in range (12)*” vai fornecer as interações que o modelo vai rodar, ou seja, para cada valor de “*n*” vai fazer um cálculo, vai fazer a mesma calibração 12 vezes fornecendo o menor erro que foi obtido com a melhor configuração. Com os valores de “*x*” e “*y*” será plotado o gráfico que fornece o resultado da simulação do modelo apresentado pela RNA.

A linha com o comando “*resultados.plot.scatter*” serve para plotar o gráfico “*n*” x “MAE” e a linha com o comando “*resultados.plot.hexbin*” plota o gráfico hexagonal, que representa a densidade dos pontos dentro do hexágono.

4. RESULTADOS E DISCUSSÕES

Este capítulo apresenta as análises feitas a partir dos dados coletados e avaliados através de métricas estatísticas, além da verificação do erro e a validação do modelo da RNA.

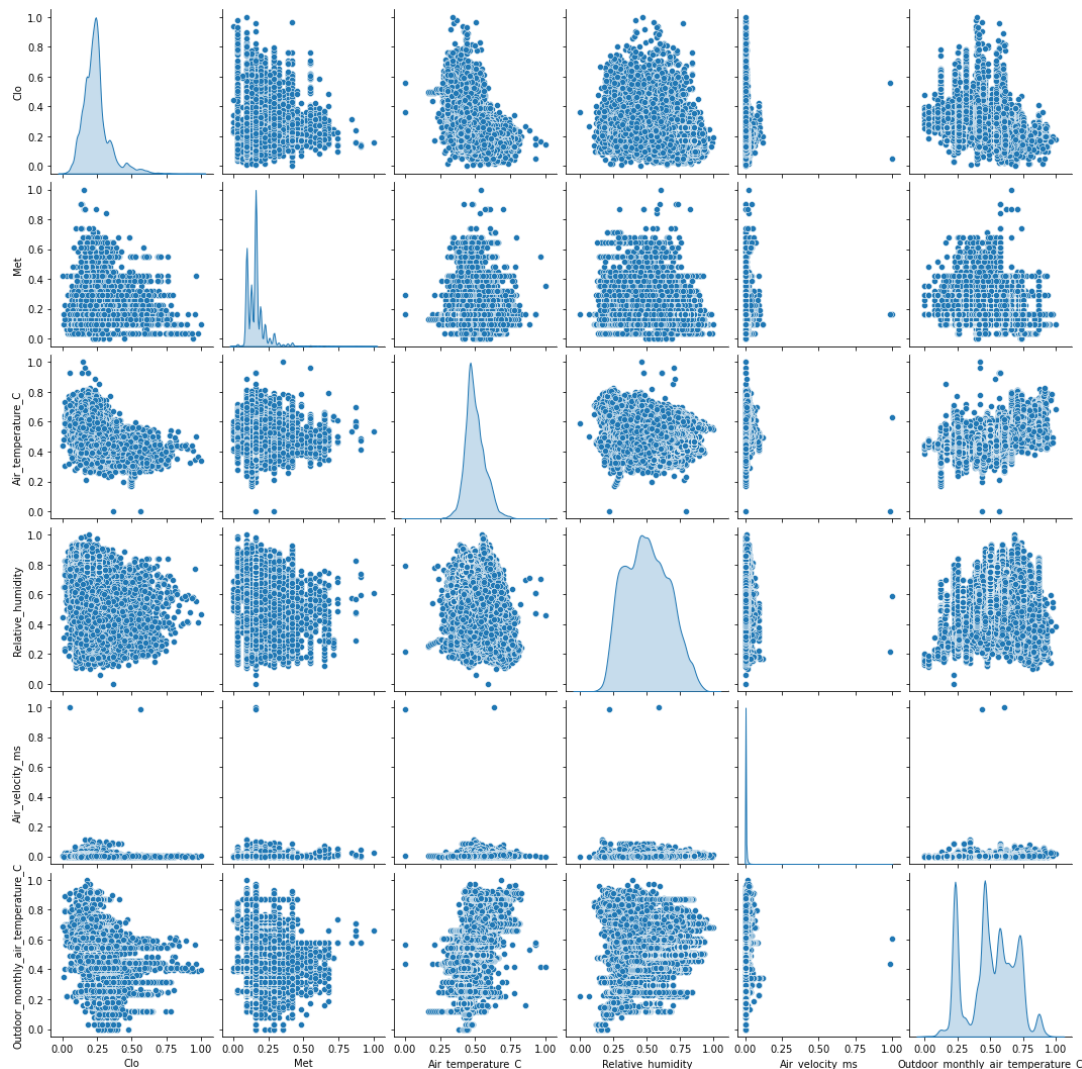
Os dados de entrada da RNA, que eram 107.583, foram alimentados em uma planilha e quando verificados dados vazios, toda aquela linha foi eliminada através do comando “*aux.dropna*”, restando 58.654 registros completos.

Os gráficos e indicadores estatísticos apresentados a seguir, tais como: valores estatísticos, erro médio absoluto (MAE: *mean absolute error*), gráfico da sensação térmica estimada *versus* observada e da análise de variância (ANOVA) foram usados para analisar a RNA.

A partir de uma análise das variáveis que compõem o banco de dados, selecionou-se para modelagem as variáveis: inércia térmica das roupas (*clo*), metabolismo (*met*), temperatura do ar (*Air_temperature_C*), umidade relativa (*Relative_Humidity*), velocidade do ar (*Air_Velocity*), temperatura mensal do ar em ambiente aberto (*Outdoor_monthly_air_temperature_C*).

A figura 10, apresenta uma matriz de correlação com gráficos de dispersão e funções de densidade de distribuição dos registros para essas variáveis. Esta associação estatística representa o grau de relação linear entre um par de variáveis. Se duas variáveis têm uma correlação positiva, significa que o aumento de uma é acompanhado pelo aumento da outra e elas estão diretamente relacionadas e existe um padrão entre elas. No caso, essa matriz mostra que as variáveis escolhidas apresentam boa correlação entre si, umas mais altas, outras mais baixas, afinal, a distribuição se apresenta aleatória e variável, e, assim, justifica o uso destas variáveis para a entrada do modelo de RNA.

Figura 10 - Matriz de correlação com gráficos de dispersão e funções de densidade de distribuição das variáveis.



Foram feitas quatro análises anteriores para encontrar a melhor solução para a RNA proposta. Algumas variações nos hiperparâmetros para descobrir se havia alteração significativa no erro foram feitas, mas o número de camadas e a variação do número de neurônios por camada se mantiveram constantes. A função de ativação usada em todas as tentativas foi a ReLU e o otimizador usado foi o *NAdam*.

A rede neural com multicamadas profundas *Feed-Forward* (FF) foi treinada com a rede triangular construída por uma camada de entrada, uma camada oculta e uma saída. A taxa de aprendizagem na primeira e na segunda tentativas foi de 0.001 e na terceira e última tentativas foi de 0.01.

O número de épocas (*epoch*) teve como *early stopping* de 11 e máximo de 1500. A proporção de treinamento e teste foi de 90:10 nas primeira e segunda tentativas e de 70:30 nas terceira e quarta tentativas.

Após otimizações no código, na segunda tentativa a acurácia passou de aproximadamente 80% para cerca de 86%.

A diferença entre a terceira e a quarta tentativas foi basicamente a mudança do *batch size* de 400 para 512, respectivamente, conforme experiência de Géron, (2019) em suas pesquisas e trabalhos de utilizar a potência de dois (2^n , com $n = 9$) para o *batch size*. Como ele explica que se pode usar qualquer valor, inicialmente foi testado valor menor e posteriormente testado a potência de dois, sem alteração significativa na RNA.

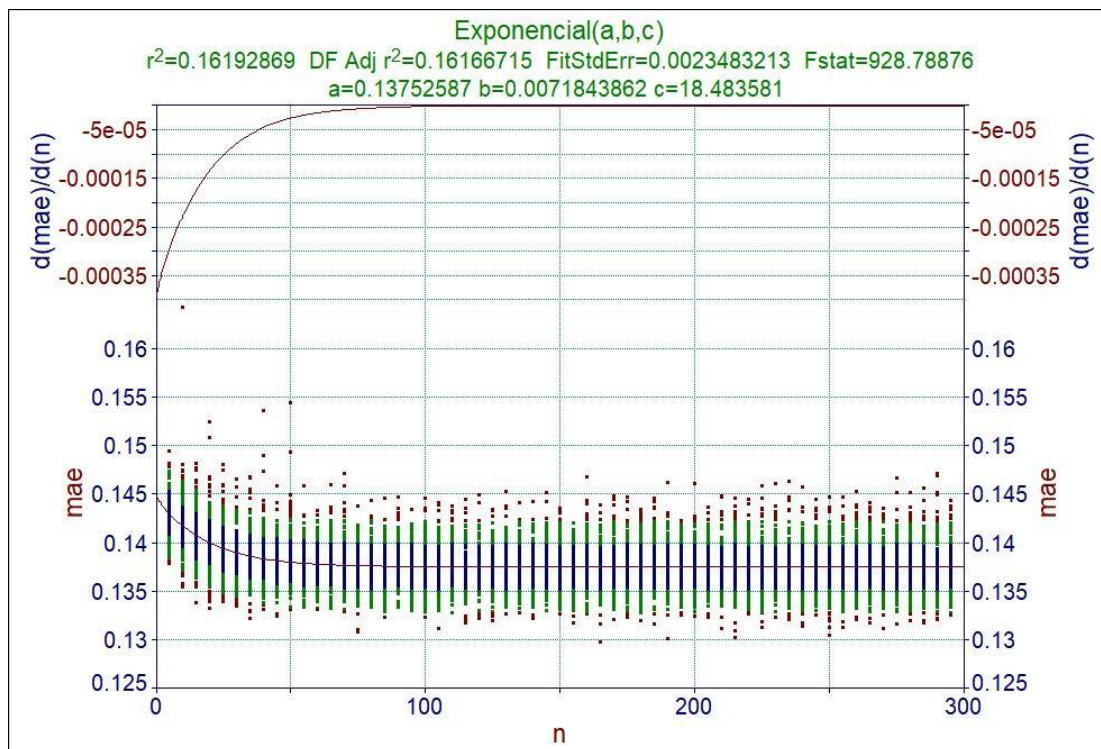
A análise da quarta tentativa, que apresentou acurácia semelhante à anterior, é mostrada a seguir.

Simulou-se a RNA variando até 300 neurônios (5, 300, 5) e validação cruzada *holdout* (70:30, com nova aleatorização por iteração), fornecendo um gráfico em que a abscissa é representada pelo número de neurônios (n) e a ordenada pelo erro (MAE), na Figura 12 (b) a seguir.

Basicamente, um conjunto de dados de treinamento foi usado para construir o modelo, enquanto o conjunto de dados de teste foi usado para avaliar a capacidade preditiva do modelo.

Finalmente, foi avaliado o desempenho do modelo RNA em diferentes conjuntos de dados de treinamento e teste baseados na proporção de 70:30 usando o erro MAE.

Figura 11 - Derivada do MAE em função do número de neurônios e MAE em função do número de neurônios.



Quando a derivada do erro se aproxima a zero ocorre um ponto de inflexão observado na curva da Figura 11, o gráfico da derivada mostra uma constância no valor do erro MAE em cerca de 0,137, com pelo menos 100 neurônios.

Observando a Figura 11, gráfico da função MAE, é possível notar que aumentando o número de neurônios o erro tende a diminuir, e isto representa o quanto o modelo está bom, quantos neurônios realmente serão necessários para a RNA.

O gráfico *hexaplot* do número de neurônios em função do erro MAE, da Figura 12, representa a densidade de neurônios em relação às diferenças de tonalidade. Tons mais claros representam concentrações menores e tons mais escuros, concentrações maiores. Nota-se a formação de uma linha separada por células escuras, que expressa

concentrações maiores em torno de um MAE de 0,137 em dois pontos aproximados de neurônios, um em 100 e outro em 150.

Nota-se que a medida que se aumenta o número de neurônios “ n ” o erro MAE começa a seguir um padrão e satura. Isto significa que aumentar o número de neurônios acima de 150 não modifica significativamente o erro (derivada tende a zero), indicando um desperdício de força computacional. No caso, foram necessárias pouco mais de 3 semanas para a análise do modelo da RNA.

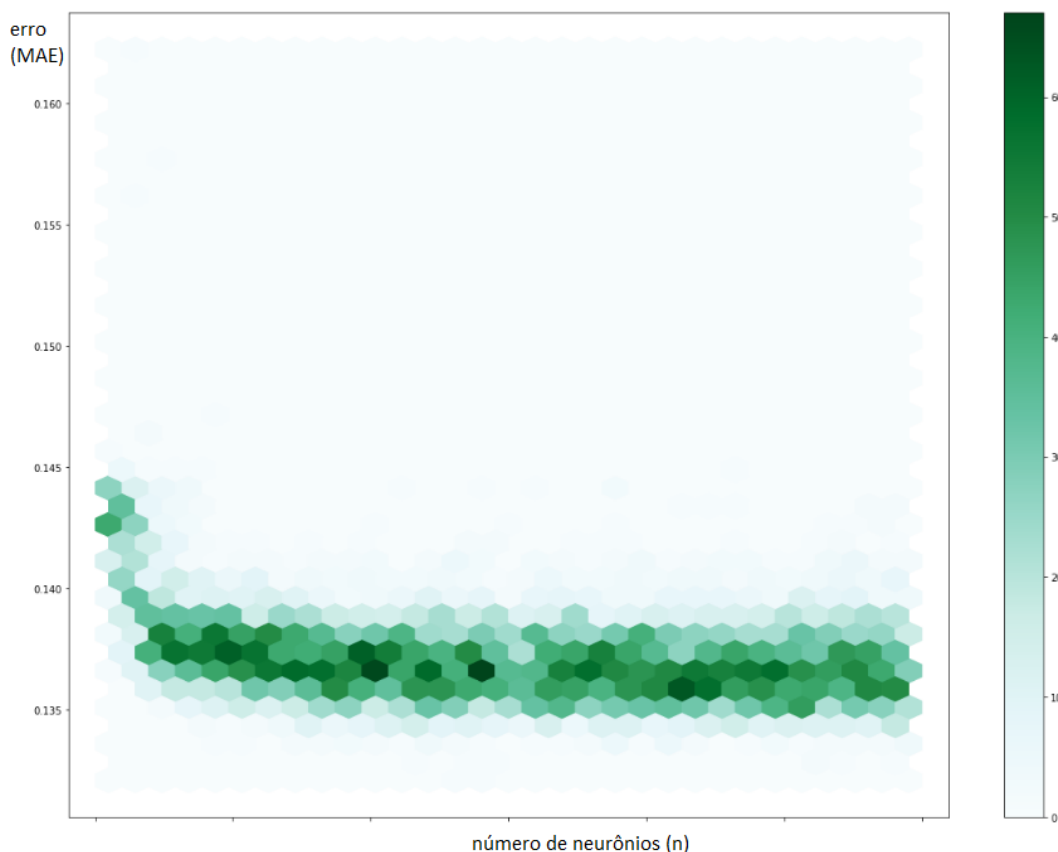
Encontrando erros cada vez menores tem-se que avaliar se o custo x benefício é satisfatório, se a RNA é bem dimensionada e adequada. Assim, não são necessários 150 neurônios, basta cerca de 100 neurônios que já fornecem uma RNA satisfatória, uma vez que o erro MAE se mantém constante em 13,7%, com a acurácia da RNA de 86,3%.

Com um número grande de iterações o erro não abaixa significativamente e indica uma possível saturação dos mesmos, talvez não compense ficar rodando tantos modelos até por limitação de máquina para processar.

A maneira de avaliar o desempenho das redes neurais é através do exame da função de perda, apresentada na figura 13. A função de perda em conjunto com o otimizador avalia a RNA e tem como objetivo reduzir o erro das previsões. Este gráfico apresenta uma aleatorização, ou seja, um caso da RNA com particionamento, não é uma média, só uma aplicação.


A taxa de aprendizagem da RNA representa a correção a cada época para atualização dos pesos usados na RNA e fornecer o menor erro possível. Neste caso, a função de perda foi otimizada pelo método NAdam, sendo que a taxa de aprendizagem de 0,01 foi usada a cada época para corrigir e atualizar os pesos. Esta escolha permitiu treinar por muitas épocas, sem, contudo, causar lentidão no aprendizado.

Figura 12 - *Hexaplot* do número de neurônios em função do erro MAE.



A evolução do desempenho da rede durante o treinamento pode ser observada na figura 13. Nota-se que no treinamento a função de perda esteve mais alta no início e decaiu rapidamente mantendo-se praticamente constante até a época final. Isto significa que o desempenho é estabilizado após 30 épocas em 0,137, embora a época máxima tenha sido de 1500.


Durante os testes, a função de perda começou com valor baixo, porque a RNA já havia sido treinada, porém houve uma maior variação da função de perda que pode ser explicada pelo uso do método de otimização da função de perda que é de descida estocástica do gradiente com um vale gradual desta função. Apesar da variação da função de perda, os testes mostraram-se parecidos com o treinamento, apresentando um erro muito próximo.

Figura 13 - Evolução da função de perda em 65 épocas.

A Figura 14 apresenta o gráfico da sensação térmica estimada versus a observada. Nota-se que o ajustamento dos valores observados e os estimados por RNAs se concentrou em algumas linhas aproximando-se de uma função exponencial, porém com alguns valores espalhados (resíduos).

A observação da forma de distribuição dos valores do ajustamento entre os valores obtidos e estimados permitem deduzir que a estimativa da sensação térmica pela RNA treinada é avaliada pela análise de variância (ANOVA).

Figura 14 - Sensação térmica estimada *versus* observada.



Para uma análise mais completa foram utilizadas as ferramentas estatísticas de regressão linear e sua análise de variância apresentadas nas tabelas 1 a 4.

Tabela 1 - Valor da regressão (b).

Modelo	R	R ²	R ² ajustado	Erro padrão da estimativa
1	,875a	,766	,766	,09973

Durante o treinamento, no qual foram calculados os pesos e os bias, o desempenho das RNAs foi monitorado para evitar o *overfitting* e *underfitting*. Na tabela 1, é possível ver que para o modelo 1, o coeficiente de correlação (R) teve o valor de 0,875, próximo de 1, indicou um alto grau de correlação.

O coeficiente de determinação (R^2) para esta rede neural é 0,766 em relação à regressão para o conjunto de dados de validação, um pouco abaixo do valor de R e de MAE, porém ainda é representativo para o modelo, considerando ainda o erro padrão de estimativa de aproximadamente 0,09973.

Na tabela 2, o valor de F (192293,48) maior que 1 e altamente significativo ($p < 5\%$) demonstra melhoria devido ao ajuste do modelo de regressão ser muito maior que sua variação no interior do modelo.

Tabela 2 - Análise de variância ANOVA (a).

Modelo	Soma dos Quadrados	df	Quadrado Médio	F	Sig. (p)
tratamento	1912,798	1	1912,798	192293,48	0,000b
erro	583,428	58652	0,009947		
Total	2496,226	58653			

a. Variável dependente: Sensação térmica observada

b. Preditores: (Constante), Sensação térmica estimada

Os parâmetros do modelo para a construção da função da sensação térmica, coeficientes não padronizados e coeficientes padronizados, são apresentados na tabela 3. Os resultados indicaram claramente que os valores estimados pelo modelo de RNAs tiveram uma relação linear mais alta com os valores observados de sensação térmica. Em termos de equação de regressão, os coeficientes também podem apresentar o desempenho de diferentes métodos. Quanto mais próximo o coeficiente angular estiver de 1, mais próximos os valores previstos estarão dos valores reais. Cada valor está associado a um erro padrão indicando até que ponto esses podem variar na amostra. A estatística t, indica que a inclinação da linha de regressão é significativamente diferente de uma linha horizontal (inclinação diferente de zero). Se o nível de significância (alfa) for menor que 0,05, então o predictor está fazendo uma contribuição significativa para o modelo. Os coeficientes padronizados não dependem das unidades de medidas variáveis. Representam o número de desvio

padrão que o “y” irá mudar como resultado de uma alteração de um desvio padrão de “x”.

Tabela 3 - Coeficientes (a).

Modelo	Coeficientes não padronizados		Coeficientes padronizados	t	Sig.	Intervalo de confiança 95,0% para B	
	B	erro padrão	Beta			Limite inferior	Limite superior
(Constante)	-0,204	0,002		-118,423	0,00	-0,207	-0,201
Sensação térmica estimada	1,006	0,002	0,875	438,513	0,00	1,001	1,010

a. Variável dependente: Sensação térmica observada

A tabela 4 apresenta a estatística dos resíduos do gráfico da sensação térmica real pela estimada e indica que os valores são pequenos e razoáveis, condizentes com um bom ajuste.

Isso indica que a faixa de sensação térmica foi aceitável e as discrepâncias podem ser devidas à variação de respostas dos indivíduos relacionadas à sua experiência térmica e aos receptores térmicos da pele para o controle adaptativo às mudanças observadas.

Tabela 4 - Estatística de resíduos (a).

	Mínimo	Máximo	Média	Desvio padrão	N
Valor previsto	-,140531	,801538	,52973	,18059	58654
Resíduos	-,456114	,40209	-,0000005	,09973	58654
Valor previsto padrão	-3,712	1,505	,000	1,000	58654
Resíduo padrão	-4,573	4,032	,000	1,000	58654

a. Variável dependente: Sensação térmica observada

Desta forma, as análises estatísticas e o erro MAE foram utilizados para avaliar o desempenho da RNA, que se apresentou satisfatório, sendo possível seu uso para predição da sensação térmica como métrica para prever o conforto térmico. Com isso, ela pode ser generalizada para outros dados de conforto térmico.

5. CONCLUSÕES

Este capítulo faz um fechamento das análises observadas anteriormente, com suas considerações mais importantes, relacionadas aos objetivos propostos para o trabalho.

Foi possível aprofundar os conhecimentos na área de microclima urbano através de revisões na área de: meteorologia e climatologia, climatologia urbana e conforto térmico. Além disso, foi possível pesquisar sobre redes neurais artificiais (RNAs) realizando revisões das áreas de: inteligência artificial, funcionamento das RNAs, ajustes de hiperparâmetros e como avaliar o desempenho da rede.

O objetivo geral de desenvolver um modelo de RNA para avaliação do conforto térmico, usando o banco de dados da *ASHRAE Global Thermal Comfort*, foi alcançado.

Os objetivos específicos (seleção dos parâmetros relevantes para a modelagem; ajuste dos hiperparâmetros de configuração da RNA; treinamento e teste da RNA; comparação dos resultados da RNA de percepção térmica observada e estimada; avaliação da acurácia da rede; e generalização da RNA) foram todos alcançados.

Com isso, foi possível entender melhor como otimizar os parâmetros existentes para minimizar a função de perda e deixar uma RNA mais eficiente. A otimização realizada forneceu um valor do erro MAE aceitável, encontrando os melhores parâmetros da rede para o problema específico que foi resolvido.

O desempenho do modelo mostrou que as condições de conforto e desconforto térmico podem ser previstas com sucesso pelos modelos da RNA.

Apesar das limitações dos modelos, os resultados do trabalho demonstraram que, a generalização da RNA validada pode ajudar na prevenção de níveis de desconforto térmico humano em áreas urbanas, da seguinte maneira: a partir de novos dados de entrada, que alimentam a RNA, são geradas saídas, que serão valores de sensação térmica ainda não conhecidos, e que servirão para indicar o nível de conforto ou

desconforto que as pessoas estão sentindo. Com isso, é possível planejar estratégias para prevenir o desconforto.

Nota-se, portanto, que a avaliação do desempenho da RNA por métricas estatísticas é importante para alcançar a melhor modelagem e prever o conforto térmico.

Baseado nos resultados apresentados, ressalta-se a importância da análise individual de cada problema de aprendizado de máquina e a otimização dos parâmetros da rede ao invés de somente utilizar os parâmetros padrões ou um conjunto aleatório. Este passo pode ser a diferença entre uma RNA boa e uma inútil.

As informações, contidas no banco de dados da ASHRAE, foram imprescindíveis para alimentar e modelar a RNA. Com isso, novos dados de entrada que surgirem, poderão ser melhor interpretados com base neste trabalho.

SUGESTÃO PARA TRABALHOS FUTUROS:

- Usar outros algoritmos de *learning machine* para comparar o desempenho dos métodos;
- Usar outras métricas de conforto térmico como saída do modelo para modelar a RNA e comparar o desempenho;
- Separar os dados do banco de dados ASHRAE por regiões climáticas e estações climáticas para verificar se as diferenças estatísticas apresentadas para as métricas de conforto térmico são significativas.

6. REFERÊNCIAS BIBLIOGRÁFICAS

AGIRRE, J. S. **Cronología de la meteorología dinámica**. Fórmula, p. 253-81, 1997.

ANOCHI, Juliana Aparecida e VELHO, Haroldo Fraga de Campos. **Previsão Climática de Precipitação para a Região Sul por Rede Neural Autoconfigurada**. Revista Ciência e Natura, Santa Maria v.38 Ed. Especial - IX Workshop Brasileiro de Micrometeorologia, p. 98 – 104. 2016.

ASHRAE/ANSI, *AMERICAN SOCIETY OF HEATING, REFRIGERATING and AIR-CONDITIONING ENGINEERS. Standard 55-2017, Thermal Environment Condition for Human Occupancy*. Atlanta: ASHRAE Engineers, Inc. 2004-2010, Atlanta, atualizada em 2017.

ASHRAE, *Global Thermal Comfort Database I e II*. Banco de Dados de conforto térmico I, 2ª versão: 1998. Banco de Dados de conforto térmico II, 2ª versão: 2014. Sob licença Open DataBase. <http://opendatacommons.org/licenses/odbl/1.0/> Disponível em: <www.comfortdatabase.com>

ABNT, ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 15220: Desempenho Térmico de Edificações**, Rio de Janeiro, 2005.

ATTHAJARIYAKUL, S. LEEPHAKPREEDA, T. *Neural Computing Thermal Comfort Index for HVAC Systems. Energy Conversion and Management. Vol. 46, Issues 15-16, p. 2553-2565*. 2005.

AYOADE, J. O. **Introdução à Climatologia dos Trópicos**. Rio de Janeiro: Bertrand Brasil, 332 p., 2001.

Benzinger, T. H. *Heat regulation: homeostasis of central temperature in man. Physiological reviews, 49(4), 671-759*. 1969.

BORGES, Rafael R.; IAROSZ, Kelly C.; BATISTA, Antonio M.; CALDAS, Iberê L.; BORGES, Fernando S. e LAMEU, Ewandson L. **Sincronização de Disparos em Redes Neurais com Plasticidade Sináptica**. Revista Brasileira de Ensino de Física. Vol. 37 N° 2. São Paulo, 2015.

CALLEJAS, Ivan Júlio Apolônio. **Avaliação Temporal do Balanço de Energia em Ambientes Urbanos na Cidade de Cuiabá - MT.** Tese (Doutorado) - Programa de Pós-Graduação em Física Ambiental. UFMT, Cuiabá - MT, 2012.

CARRACA M.G.D. e COLLIER C.G. **Influência da morfologia urbana na distribuição da precipitação na Grande Manchester. Cidades e Alterações climáticas. Que futuro?** Universidade de Lisboa, Portugal. p. 15-16, 2008.

CHAI, Qian; WANG, Huiqin; ZHAI, Yongchao and YANG, Liu. ***Using Machine Learning Algorithms to Predict Occupants' Thermal Comfort in Naturally Ventilated Residential Buildings.*** *Journal Energy & Buildings*, ed. n° 217, 109937. 2020.

CHALINE, J. ***Histoire de l'homme et des climats au quaternaire.*** Paris: Doin Editeurs, 1985.

CHAPMAN, S.; WATSON, J. E. M.; SALAZAR, A.; THATCHER, M.; MCALPINE, C. A. ***The impact of urbanization and climate change on urban temperatures: a systematic review.*** *Landscape Ecology*. Agosto, 2017.

CIUHA, U.; MEKIAVIC, I. B. ***Regional Thermal Comfort Zone in Males and Females.*** *Physiology & Behavior*, v. 161, JUL, p. 123 – 129. 2016.

COUTINHO, Antônio Souto. **Conforto e insalubridade térmica em ambientes de trabalho.** João Pessoa. PPGE. 1998.

CUNHA, Davi Gasparini Fernandes, VECCHIA, Francisco. **As Abordagens Clássica e Dinâmica de Clima: uma Revisão Bibliográfica Aplicada ao Tema da Compreensão da Realidade Climática.** Revista: Ciência e Natura, vol. 29, núm. 1, pp. 137-149. UFSM, Brasil, 2007.

DANNI-OLIVEIRA, Inês Moresco e MENDONÇA, Francisco. **Climatologia: Noções Básicas e Climas do Brasil.** São Paulo: Oficina de textos, 2007.

DE DEAR, Richard; BRAGER, Gail; COOPER, Donna. *Developing an Adaptive Model of Thermal Comfort and Preference. Final Report, ASHRAERP-844, March, 1997.*

de P'ADUA BRAGA, A., LEON F. de Carvalho, e LUDERMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações.** LTC, 2 edição. 2007.

DIETTERICH, T. *Overfitting and Undercomputing in Machine Learning. Computing Surveys (CSUR), ACM, v. 27, n. 3, 1995.*

DOZAT, Timothy. *Incorporating Nesterov Momentum into Adam. Workshop track: ICLR - International Conference on Learning Research, 2016.*

EVANGELISTA, Francisco Igor Siqueira. **Previsão Climática Sazonal para a Região Hidrográfica dos Sertões de Crateús Utilizando Redes Neurais Artificiais.** Trabalho de Conclusão de Curso de Engenharia Civil. Universidade Federal do Ceará. 2019.

FALZON, Pierre. *Ergonomie. Edgard Blücher. 3ª ed. Presses Universitaires de France.* 2014.

FANGER, Polv Ole. *Thermal Comfort: Analysis and Applications in Environmental Engineering.* McGraw-Hill, New York, EUA, 1970.

FAUSETT, L. V. **Fundamentals of neural networks: architectures, algorithms and applications.** Pearson Education India. 2006.

FERNANDES, Tatiana Jorgetti. **Previsão do tempo e comunicação sempre de mãos dadas.** Cienc. Cult. vol.72 no.1 São Paulo Jan./Mar. 2020.

FÖLDVÁRY, Veronika Ličina; CHEUNG, Chin To; ZHANG, Hui; DE DEAR, Richard; PARKINSON, Thomas; ARENS, Edward; CHUN, Chungyoon; LUO, Maohui; BRAGER, Gail; LI, Peixian; KAAM, Soazig; ADEBAMOWO, Michael; ANDAMON, Mary; BABICH, Francesco; BOUDEN, Chiheb; BUKOVIANSKA, Hana; CANDIDO, Christhina; CAO, Bin ZHOU, Xiang. *Development of the*

ASHRAE Global Thermal Comfort Database II. Journal Building & Environment. 2018.

FRANÇA, M. S. **Estimativa de índices de conforto térmico por meio do uso de transecto móvel em Sorriso/MT.** *Nativa, Cuiabá*, v. 6, n. 6, p. 648-653, Novembro 2018.

FRANCO, Muriel F., FERRUGEM, Anderson P., SILVEIRA, Antônio César B. **Redes Neurais Aplicada na Automação de uma Residência Energeticamente Eficiente.** *Blucher Mechanical Engineering Proceedings*. vol. 1 , num. 1. In: 10^o World Congress on Computational Mechanics. 2014.

FROTA, Anésia Barros e SCHIFFER, Sueli Ramos. **Manual de conforto térmico.** 5. ed. São Paulo: Studio Nobel, 2001.

GAGGE, A. et al. *A standard predictive index of human response to the thermal environment.* *ASHRAE Trans*, 92, p. 709-731, 1986.

GAGGE, A. et al. *Comfort thermal sensations and associated physiological responses at various ambient temperatures.* *Environ. Res.*, n. 1, p. 1-20, 1967.

GARTLAND, L. **Ilhas de calor: como mitigar zonas de calor em áreas urbanas.** São Paulo: Oficina de Textos, 2010.

GALVÃO, Noemi Dreyer; MARIN, Heimar de Fátima. **Técnica de mineração de dados: uma revisão da literatura.** *Acta Paulista de Enfermagem*. vol.22, n.5 São Paulo. Sept./Oct. 2009.

GÉRON, Aurélien - *Hands on Machine Learning with Scikit Learn Keras and Tensorflow - Concepts, Tools, and Techniques to Build Intelligent Systems.* Ed. O'Reilly Media, 2nd edition, Jupyter, Canada, 2019.

GLOROT, Xavier, BORDES, Antoine and BENGIO, Yoshua. **Deep Sparse Rectifier Neural Networks.** *Appearing in Proceedings of the 14th International Conference on Artificial Intelligence and Statistics (AISTATS), Vol. 15, Fort Lauderdale, USA.* 2011.

GOODFELLOW, Ian, BENGIO, Yoshua e COURVILLE, Aaron. ***Deep Learning***. Ed. MIT Press. 2016.

HAMBLIN, W.K; CHRISTIANSEN, E.H. ***Earth's Dynamic Systems***. 7a ed. London: Prentice Hall, 1995.

HUMPHREYS, M., A., NICOL, F. ***Conflicting Criteria for Thermal Sensation within the Fanger Predicted Mean Vote Equation***. In: CIBSE/ASHRAE JOINT NATIONAL CONFERENCE, Proceedings. 1996.

HANIEF, M.; WANI, M.F.; ***Modeling prediction of surface roughness for running in wear using Gauss-Newton algorithm ANN***. Applied Surface Science, V. 367, Part B, Pages 1673-1677, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.apsusc.2016.10.062>>.

HAQUE, M. A.; ALEX, J. S. R.; VENKATESAN, N. ***Evaluation of Modified Deep Neural Network Architecture Performance for Speech Recognition***. International Conference on Intelligent Advanced System (ICIAS), 2018.

HARARI, Yuval Noah. **Homo Deus: uma breve história do amanhã**. Tradução: Paulo Geiger. 1ª ed. São Paulo: Companhia das Letras, 2016.

HAYKIN, Simon. **Redes Neurais Artificiais: Princípios e práticas**. 2ª edição, Editora Bookman, Porto Alegre, 2001.

HAYKIN, Simon. ***Neural Networks and Learning Machines***. 3 edition. 2009.

HINTON, G.E. ***Learning multiple layers of representation***. Trends in Cognitive Sciences, 11, pp. 428–434, 2007.

HIRASHIMA, S. Q. S. **Percepção sonora e térmica e avaliação de conforto em espaços urbanos abertos do município de Belo Horizonte – MG, Brasil**. São Paulo, 2014. 248f. Tese (Doutorado em arquitetura e urbanismo) - Universidade de São Paulo, São Paulo, 2014.

HÖPPE, Peter. *The physiological equivalent temperature: a universal index for the biometeorological assessment of the thermal environment*. *Int J Biomet* 43, pp. 71–75. 1999.

HÖPPE, Peter e MAYER H. *Planungsrelevante Bewertung der thermischen Komponente des Stadtklimas*. *Landschaft Stadt* n. 19, pp. 22–29. 1987.

HOUGHTEN et al. *Determining lines of equal comfort*. *ASHVE Trans.*, v.29, p.163-169, 1923.

HOWARD, Luke. **Climate**. 1ª versão - Ano publicação: 1818. CHANDLER. Adaptação: **The climate of London**. International Association for Urban Climate (IAUC), 1950.

IBM SPSS Neural Networks 24 - Intellectual Property Licensing Legal Intellectual Property Law. IBM, Japan Ltd. 19-21, Nihonbashi-Hakozakicho, Chuo-ku, Tokyo, 103-8510, Japan. 2016. Disponível em: <www.ibm.com/legal/copytrade.shtml>

INSTITUTO BRASILEIRO DE GEOGRAFIA, IBGE. *Cidades e Estados: Cuiabá - MT*. <https://www.ibge.gov.br/cidades-e-estados/mt/cuiaba.html> Visitado em 30/04/2020.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION, ISO 7730. *Ergonomics of the thermal environment - Analytical determination and interpretation of thermal comfort using calculation of the PMV and PPD indices local thermal comfort criteria*. Genebra, Switzerland, 1ª Versão: 1994, Versão Atual: 2005.

INTERNATIONAL ORGANIZATION FOR STANDARDIZATION, ISO 10551. *Ergonomics of the thermal environment - Assessment of the influence of the thermal environment using subjective judgment scales*. Genebra, Switzerland, 1995.

JAUREGUI, E. *The urban climate of Mexico city*. *Erdkunde*, 28, pp. 298-307, 1973.

JUNIOR, G. de B. V., FILENI, C. H. P. e PASSOS, R. P. **Redes Neurais Recorrentes: Aplicabilidade na Análise do Movimento Humano e na Saúde.** Revista CPAQV - Centro de Pesquisas Avançadas em Qualidade de Vida - CPAQV Journal. V 12, nº 1. 2020.

KARIMINIA, Shahab, MOTAMEDI, Shervin, SHAMSHIRBAND, Shahaboddin, PIRI, Jamshid, MOHAMMADI, Kasra, HASHIM, Roslan, ROY, Chandrabhushan, PETKOVIĆ, Dalibor BONAKDARI, Hossein. *Modelling thermal comfort of visitors at urban squares in hot arid climate using NN-ARX soft computing method. PORTRAITED ARTICLE in 2020. Theoretical Applied Climatology. Vol 124, p. 991-1004.* 2016.

KANDEL, Ibrahim and CASTELLI, Mauro. *The effect of batch size on the generalizability of the convolutional neural networks on a histopathology dataset. The Korean Institute of Communications and Information Sciences (KICS). Publishing services by Elsevier.* 2020.

KHALIL, H. A. E. E.; IBRAHIM, A.; ELGENDY, N.; MAKHLOUF, N. *Could/should improving the urban climate in informal areas of fast-growing cities be an integral part of upgrading processes? Cairo case. Urban Climate. v. 24. p. 63-79,* 2018.

KETTERER, Christine; MATZARAKIS, Andreas. *Mapping the Physiologically Equivalent Temperature in urban areas using artificial neural network. Landscape Urban Planning, Volume 150, June 2016, Pages 1-9.* 2016.

KOVÁCS, Zsolt László. **Redes Neurais Artificiais, Fundamentos e Aplicações.** 4ª edição revista. Editora Livraria da Física. PUC-SP. São Paulo, 2006.

LABAKI, L. C. **conforto térmico em Espaços Público de Passagem: estudo em ruas de pedestres no estado de São Paulo.** Ambiente Construído, Porto Alegre, v. 12, n. 1, p. 167-183, jan./mar. 2012.

LAMBERTS, R; DUTRA, L; PEREIRA, F.O.R. **Eficiência Energética na Arquitetura.** São Paulo PW Editores. 192 p. 1997.

LECUN, Y.; BENGIO, Y.; HINTON, G. *Deep Learning*. Nature Publishing Group, v. 521, n. 7553, p. 436, 2015.

LIU, Weiwei; LIAN, Zhiwei; ZHAO Bo. *A neural Network Evaluation Model for Individual Thermal Comfort*. *Journal Energy Buildings*. Vol. 39, Issue 10, p 1115-1122. 2007.

LONG, J. R.; GREGORIOU, V. G.; GEMPERLINE, P. J. *Spectroscopic Calibration Quantitation Using Artificial Neural Networks*. *Analytical Chemistry, ACS Publications*, v. 62, n. 17, p. 1791–1797, 1990.

LU, Siliang; WANG, Weilong; LIN, Chaochao; HAMEEN, Cochran. *Data-Driven Simulation of a Thermal Comfort-Based Temperature Set-Point Control With ASHRAE RP884*. *Journal Building Environment*, n° 156, p 137-146. 2019.

LUO, Maohui; XIE, YAN, Yichen; KE, Zhihao; YU, Peiran; Wang, Zi; ZHANG, Jingsi. *Comparing Machine Learning Algorithms in Predicting Thermal Sensation Using ASHRAE Comfort Database II*. *Energy & Buildings*, n° 210, 109776. 2020.

MAITELLI, Gilda Tomasini. *Uma abordagem tridimensional de clima urbano em área tropical continental: o exemplo de Cuiabá-MT*. 220f. Tese (Doutorado em Geografia) - Faculdade de Filosofia, Letras e Ciências Humanas, USP, São Paulo - SP, 1994.

MANDIC, D. P.&CHAMBERS, J. A. *Recurrent Neural Networks for Prediction*. Wiley. 2001.

MATHEW, Aneesh, SREEKUMAR, Sreenu, KHANDELWAL, Sumit; KUMAR, Rajesh. *Prediction of land surface temperatures for surface urban heat island assessment over Chandigarh city using support vector regression model*. *Solar Energy Journal*. Vol. 186, p. 404-415. 2019.

MATZARAKIS, A.; RUTZ, F. *Application of the RAYMAN Model in Urban Environments*. Freiburg: Meteorological Institute, University of Freiburg, 2010.

McCARTHY, J. *What is Artificial Intelligence?* 2004. Disponível em <<http://www.formal.stanford.edu/jmc/whatisai/whatisai.html>> Acesso em 15/05/2020.

McCULLOCH, W. S.; PITTS, W. (1943). *A logical Calculus of the Ideas Immanent in Nervous Activity*. *Bulletin of Mathematical Biophysics*, 5: p 115–133. 1943.

McKNIGHT, Tom L; DARREL, Hess (2000). *Climate Zones and Types: The Köppen System. Physical Geography. A Landscape Appreciation. Upper Saddle River, NJ: Prentice Hall*. p. 200–1. 2000.

MIRZAEI, Parham A., OLSTHOORN, Dave, TORJAN Michael, HAGHIGHAT, Fariborz. *Urban neighborhood characteristics influence a building's indoor environment*. *Journal Sustainable Cities Society*. Vol. 19. 2015.

MONTEIRO, L. M.; ALUCCI, M. P. **Questões Teóricas de conforto térmico em Espaços Abertos: consideração histórica, discussão do estado da arte e proposição de classificação de modelos**. *Ambiente Construído*, Porto Alegre, v. 7, n. 3, p. 43-58, jul./set. 2007.

MONTEIRO, Carlos Augusto de Figueiredo. **Análise rítmica em climatologia**. *Climatologia*, São Paulo: IGEO/USP, n. 1, 21 p., 1971.

MONTEIRO, C. A. F. **Teoria e clima urbano**. 25. São Paulo: IGEOG/USP, 1976.

MONTEIRO, Carlos Augusto de Figueiredo, MENDONÇA, Francisco de Assis. **Clima Urbano**. São Paulo: Editora Contexto, 2003.

MORAES, Osvaldo Luiz Leal de e ACEVEDO, Otávio Costa. **Camada Limite Planetária – Problemas com Medições e Interpretação de Dados**. ABCM, IV Escola de Primavera de Transição e Turbulência Universidade Federal do Rio Grande do Sul, Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre, RS, 2004.

MOUSTRIS, Konstantinos, TSIROS, Ioannis X., TSELIU, Areti; NASTOS, Panagiotis. *Development Application of Artificial Neural Network Models to*

Estimate Values of a Complex Index of Human Thermal Comfort Associated with Urban Heat and Cold Island Patterns, Using Air Temperature Data from a Standard Weather Station. International Journal of Biometeorology. Vol. 62, p. 1265-1274. 2018.

MOUSTRIS, Konstatinos, TSIROS, Ioannis X., ZIOMAS, Ioannis C.&PALIATSOS, Athanasios G. *Artificial neural network models as a useful tool to forecast human thermal comfort using microclimatic bioclimatic data in the great Athens area (Greece). Journal of Environmental Science Health, Toxic/Hazardous Substances Environmental Engineering. Vol 45. Issues 4. Pages 447-453. 2010.*

NGUYEN, Quang Hung, LY, Hai-Bang, HO, Lanh Si, AL-ANSARI, Nadhir, LE, Hiep Van, TRAN, Van Quan, PRAKASH, Indra and PHAM, Binh Thai. *Influence of Data Splitting on Performance of Machine Learning Models in Prediction of Shear Strength of Soil. Mathematical Problems in Engineering. Artificial Intelligence for Civil Engineering. 2021. Disponível em: <(https://www.hindawi.com/journals/mpe/2021/4832864/)>*

OKE, Timothy Richard. *Boundary Layer Climates. 1ª Ed. Editora: Methuen & Co, Vancouver, Canadá, 1978.*

OKE, Timothy Richard. *Canyon geometry the nocturnal urban heat island: comparison of scale model field observations. Journal of Climatology, n. 1, pp. 237-25, 1981.*

OKE, Timothy Richard. *The energetic basis of the urban heat island. Quart. Journal. Roy. Met. Soc., 108, pp. 1-24.1982.*

OKE, T. R. *Initial guidance to obtain representative meteorological observations at urban sites. IOM Report, TD. World Meteorological Organization, Geneva, 2006.*

OKE, T.R., MILLS, G., CHRISTEN, A., VOOGT, J.A. - *Urban Climates. Cambridge University Press. 2017.*

PANDORFI, Héilton, SILVA, Iran José Oliveira, SARNIGHAUSEN, Valéria Cristina Rodrigues, VIEIRA, Frederico Márcio Corrêa, NASCIMENTO, Sheila

Tavares, GUISELINI, Cristiane. **Uso de redes neurais artificiais para predição de índices zootécnicos nas fases de gestação e maternidade na suinocultura.** Revista . Bras. Zootec., v.40, n.3, p.676-681, 2011.

PATEL, D. A.; JHA, K. N. *Neural Network Approach for Safety Climate Prediction.* *Journal of Management in Engineering*, v. 31, n. 6, 2014.

PATTERSON, J.; GIBSON, A. *Deep Learning: A Practitioner's Approach.* San Francisco, CA: O'Reilly Media, Inc., 538 p. 2017.

RTQ-C: Regulamento Técnico da Qualidade para o Nível de Eficiência Energética de Edificações Comerciais, de Serviços e Públicas. Instituto Nacional de Metrologia, Normalização e Qualidade Industrial – Inmetro. Divisão de Programas de Avaliação da Conformidade – Dipac, Rio de Janeiro, 2013.

RUNGTA, Krishna. *TensorFlow Learn in 1 Day: Make your Own Neural Network.* 2018.

SALAME, Camil Wadih, QUEIROZ, Joaquim Carlos Barbosa, SOUZA, Everaldo Barreiros de, FARIAS, Valcir João da Cunha, ROCHA, Edson José Paulino da e MOURA, Helyelson Paredes. **Um Estudo Comparativo dos Modelos Box-jenkins e Redes Neurais Artificiais na Previsão de Vazões e Precipitações Pluviométricas da Bacia Araguaia, Tocantins, Brasil.** Revista Brasileira de Ciências Ambientais. n.52, jun 2019, p. 28-43. 2019.

SANT'ANNA NETO, João Lima. **História da Climatologia no Brasil.** Tese (Livro Docência), UNESP/FCT, 2001.

SEGAWA, Hugo. **Clave de Sol: notas sobre a história do conforto ambiental.** Revista da ANTAC, Porto Alegre, v.3, n. 2, p 37-46, abr./jun. 2003.

SILVA, A. N. R. D., RAMOS, R. A., SOUZA, L. C. L., RODRIGUES, D. S., & MENDES, J. F.. **SIG: uma plataforma para introdução de técnicas emergentes no planejamento urbano, regional e de transportes.** São Carlos, SP. Ed. autores, 2004.

SILVA, Ivanize Cláudia dos Santos e. **Índice ambiental urbano (IAU): uma contribuição ao estudo do planejamento e do conforto térmico em espaços abertos.** 2017. 238f. Tese (Doutorado em Arquitetura e Urbanismo) - Centro de Tecnologia, Universidade Federal do Rio Grande do Norte, Natal, 2017.

SORRE, Max. *Les Fondements de la Géographie Humaine: les Fondements Biologiques.* 3^a Ed., Librairie Armand Colin, Paris. 1957.

SRIVASTAVA, Nitish, HINTON, Geoffrey, KRIZHEVSKY, Alex, SUTSKEVER, Ilya, SALAKHUTDINOV, Ruslan. **Dropout: A Simple Way to Prevent Neural Networks from Overfitting.** *Journal of Machine Learning Research* 15. 2014.

STATHAKIS, D. **How many hidden layers and nodes?** *International Journal of Remote Sensing Vol. 30, No. 8. Institute for the Protection and Security of the Citizen (IPSC), Monitoring Agriculture with Remote Sensing (MARS), Ispra, Italy, 20 April 2009.*

STEWART, I. D; OKE, T. R. **Local climate zones for urban temperature studies.** *Bulletin of the American Meteorological Society*, v. 93, n. 12, p. 1879-1900, 2012.

THEEUWES, N.E.; STEENEVELD, G.J.; RONDA, R.J; HOLTSLAG, A.A. **A diagnostic equation for the daily maximum urban heat island effect for cities in northwestern Europe.** *Int. J. Climatol.*, 37 (1), pp. 443-454. 2017.

THEODORIDIS, Sergios. **Machine Learning: A Bayesian Optimization Perspective, 2^a ed.** Elsevier Ltd. Copyright © 2020. Disponível em: <<https://doi.org/10.1016/B978-0-12-818803-3.00030-1>> Acesso em: Janeiro, 2021.

THOMÉ, A. C. G. **Redes neurais: uma ferramenta para kdd e data mining.** Material Didático. (2002). Disponível em: <http://equipe.nce.ufrj.br/thome/grad/nn/mat/apostila_kdd_mbi> Acesso em: Outubro, 2020.

TORRES, José Luis; MARTIN, Marcelo Luis. **Adaptive Control of Thermal Comfort Using Neural Networks.** *Argentine Symposium on Computing Technology.* 2008.

VAPNIK, V. N. *The nature of statistical learning theory*. Nova York: Springer-Verlag, 188p. 1995. Disponível em: <<https://dl.acm.org/doi/book/10.5555/211359>> Acesso em: Mai, 2021.

VAREJÃO-SILVA, Mário Adelmo, **Meteorologia e Climatologia**, versão digital 2, Recife-BR, Março, 2006.

VECCHI, Renata de, **Avaliação de Conforto Térmico em Edificações Comerciais que Operam sob Sistemas Mistos de Condicionamento Ambiental em Clima Temperado e Úmido**. Tese apresentada ao programa de pós-graduação em Engenharia Civil da Universidade Federal de Santa Catarina, Florianópolis, 2015.

VERNON, H. M.; WARNER, C. G. *The influence of the humidity of the air on capacity for work at high temperatures*. *J. Hyg.*, v.32, p.431– 462, 1932 .

WANG, Zhe; WANG, Jingyi; HE, Yueer; LIU, Yanchen; LIN, Borong; HONG, Tianzhen. *Dimension analysis of subjective thermal comfort metrics based on ASHRAE Global Thermal Comfort Database using machine learning*. *Journal of Building Engineering*, n° 29, 101120. 2020.

WIKI, Series. **Meteorologia**. Editora : Books LLC, Wiki Series (24 junho 2011). ISBN-10 : 1232522775, ISBN-13 : 978-1232522775. Ano: 2011.

XAVIER, Antonio Augusto de Paula - **Predição De Conforto Térmico Em Ambientes Internos Com Atividades Sedentárias - Teoria Física Aliada A Estudos De Campo**. Tese apresentada ao Departamento de Engenharia de Produção da Universidade Federal de Santa Catarina, Florianópolis, 2020.

YANG, Xiaoshan, YAO, Lingye, PENG, Lilliana, JIANG, Zhidian, JIN, Tao; ZHAO, Lihua. *Evaluation of a diagnostic equation for the daily maximum urban heat island intensity its application to building energy simulations*. *Energy Building*. Vol. 193. p. 160-173. 2019.

YAO, R.; WANG, L.; HUANG, X.; ZHANG, W.; LI, J.; NIU, Z. *Interannual variations in surface urban heat island intensity associated drivers in China*. *Journal of Environmental Management*. n. 222, p. 86-94, 2018.

YASSIN, M. A.; ALAZBA, A. A.; MATTAR, M. A. *Artificial neural networks versus gene expression programming for estimating reference evapotranspiration in arid climate*. *Agricultural Water Management*, v. 163, p. 110-124, Jan. 2016.

ZAVATTINI , João Afonso. **A produção brasileira em climatologia: o tempo e o espaço nos estudos do ritmo climático**. Revista, Terra Livre, n. 20,pp. 65-100, 2003.