

UNIVERSIDADE FEDERAL DA GRANDE DOURADOS
FACULDADE DE CIÊNCIAS AGRÁRIAS
Programa de Pós-Graduação em Engenharia Agrícola

**Modelagem Ambiental com Rede Neural Artificial para Avaliação
de Impactos Resultantes da Antropização Rural**

CLAUDEIR DE SOUZA SANTANA

DOURADOS
MATO GROSSO DO SUL
2022

Modelagem Ambiental com Rede Neural Artificial para Avaliação de Impactos Resultantes da Antropização Rural

CLAUDEIR DE SOUZA SANTANA
TECNÓLOGA EM CONTROLE DE OBRAS

Orientador: Prof. Dr. Rodrigo Couto Santos

Dissertação apresentada à Universidade Federal da Grande Dourados, como parte das exigências do Programa de Pós-Graduação em Engenharia Agrícola, para obtenção do título de Mestre.

DOURADOS
MATO GROSSO DO SUL
2022

Dados Internacionais de Catalogação na Publicação (CIP).

S232m Santana, Claudeir De Souza

Modelagem ambiental com rede neural artificial para avaliação de impactos resultantes da antropização rural [recurso eletrônico] / Claudeir De Souza Santana. -- 2022.

Arquivo em formato pdf.

Orientador: Rodrigo Couto Santos.

Coorientador: Tiago Ismaier de Carvalho.

Dissertação (Mestrado em Engenharia Agrícola)-Universidade Federal da Grande Dourados, 2022.

Disponível no Repositório Institucional da UFGD em:

<https://portal.ufgd.edu.br/setor/biblioteca/repositorio>

1. Conforto ambiental. 2. Êxodo rural. 3. Segmentação semântica. I. Santos, Rodrigo Couto. II. Carvalho, Tiago Ismaier De. III. Título.

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

©Direitos reservados. Permitido a reprodução parcial desde que citada a fonte.

**MODELAGEM AMBIENTAL COM REDE NEURAL ARTIFICIAL PARA
AVALIAÇÃO DE IMPACTOS RESULTANTES DA ANTROPIZAÇÃO RURAL.**
por

Claudeir de Souza Santana


Dissertação apresentada como parte dos requisitos exigidos para obtenção do título
de MESTRE EM ENGENHARIA AGRÍCOLA

Aprovada em: 26/10/2022.



Prof. Dr. Rodrigo Couto Santos
Engenheiro Agrícola


Prof. Dr. Rodrigo Couto Santos
Orientador – UFGD



Prof. Dr. Arthur Carniato Sanches
UFGD



Prof. Dr. Rodrigo Aparecido Jordan
UFGD



Prof. Dr. Hélio Ávalo
UCDB



Prof. Dr. Tiago Ismaier de Carvalho
IFMS

DEDICATÓRIA

Aos meus pais Eudes e Maria Zilda,
meus exemplos de vida e maiores incentivadores
das realizações dos meus sonhos.

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter guiado e dirigido os meus passos para mais uma etapa dos meus sonhos.

Sou imensamente grata aos meus familiares, pois foram essenciais para concretização deste sonho. Em especial a minha companheira Kárita pela compreensão nos momentos mais difíceis, além de todo auxílio e dedicação na fase experimental desta pesquisa.

Ao Prof. Dr. Rodrigo Couto Santos pela oportunidade, confiança e ensinamentos que adquiri sendo sua orientada.

Ao Prof. Dr. Tiago Ismaier de Carvalho pela paciência, dedicação e empenho na coorientação deste trabalho.

Aos professores e servidores do Programa de Pós-Graduação em Engenharia Agrícola da Universidade Federal da Grande Dourados (UFGD).

Aos amigos Luana e João pelo auxílio na fase experimental da pesquisa.

A amiga Maria pela contribuição nas análises estatísticas.

Aos amigos e colegas de trabalho Joyce Oliveira e Adelson Mesquita pelo auxílio e troca de conhecimentos.

Ao meu colega de trabalho e de Pós-graduação (mestrado), Fagner Theodoro pela parceria e troca de conhecimentos.

RESUMO

SANTANA, C. S. **Modelagem Ambiental com Rede Neural Artificial para Avaliação de Impactos Resultantes da Antropização Rural**. Dourados, 2021. 114f. Dissertação (Mestrado) - Programa de Pós-graduação em Engenharia Agrícola, Universidade Federal da Grande Dourados.

O agronegócio brasileiro continua crescendo em ritmo forte, e essa área mostra o quanto tem fortalecido a economia nacional ao longo dos anos. Nesse contexto de desenvolvimento, ocorre a expansão populacional das áreas rurais, ampliando a malha urbana de grandes regiões e transformando alguns territórios de seu entorno em áreas antropizadas. Ocorre que esse progresso exige mudanças na paisagem natural para atender às necessidades básicas de seus habitantes, que aumenta proporcionalmente a esse desenvolvimento. No entanto, essas transformações geralmente ocorrem sem o devido planejamento, favorecendo o processo de mudança climática local. Diante do exposto, esta pesquisa teve como objetivo avaliar as condições ambientais que representam diferentes tipos de ocupação em uma área rural urbanizada, comparando microclimas e representando as características dos ambientes em um algoritmo computacional que deve atribuir uma classificação indicando a qualidade ambiental dessas áreas. A primeira parte da pesquisa consistiu nos experimentos de coleta de dados que foi realizado na cidade de Dourados - MS na Unidade II da Universidade Federal da Grande Dourados (UFGD). Considerando diferentes tipos de cobertura de superfície, os elementos climáticos temperatura e umidade relativa do ar foram coletados durante 40 dias de inverno (frio) e 40 dias de verão (calor), utilizando um sistema automático de aquisição de dados Datalogger Wireless em 9 microambientes e um banco de dados do INMET. Os dados foram posteriormente convertidos no Índice de Temperatura e Umidade (ITU). Os valores de ITU permitiram classificar os ambientes de acordo com as faixas relacionadas às zonas de conforto para diferentes microclimas. A segunda parte do estudo consistiu em desenvolver um modelo lógico-matemático envolvendo uma Rede Neural Artificial do cenário criado para classificar o ambiente estudado de acordo com o índice de bem-estar humano (IBEH) em uma escala que varia de muito ruim a muito bom. A rede neural proposta possui uma camada de entrada com doze neurônios, uma camada oculta com dezoito neurônios e uma camada de saída com cinco neurônios. A rede neural artificial elaborada mostrou-se eficiente em sua fase de treinamento, onde correspondeu a valores de aproximadamente 90% de precisão, e na fase de teste, a uma precisão média de 80%. No entanto, o fato de o IBEH estar correlacionado com o ITU influenciou o desenvolvimento de uma segunda proposta de algoritmo removendo o neurônio de referência. Esta alteração levou à necessidade de alterar os parâmetros da rede para obter o seu melhor desempenho. Mesmo com todos os ajustes empíricos realizados, a acurácia da rede foi de 62%. Por ser a primeira arquitetura complexa construída para indicação multiclasse de conforto ambiental local, pode-se concluir que o algoritmo refletiu bem os ambientes estudados envolvendo a interação de recursos naturais e espaços construídos.

Palavras-chave: Conforto ambiental; Êxodo rural; Segmentação semântica.

ABSTRACT

SANTANA, C. S. **Environmental Modeling with Artificial Neural Network for Evaluation of Impacts Resulting from Rural Anthropization.** Dourados, 2021. 114f. Dissertation (Masters) - Postgraduate Program in Agricultural Engineering, Federal University of Grande Dourados.

Brazilian agribusiness continues to grow at a strong pace, and this area shows how much it has strengthened the national economy over the years. In this context of development, the population expansion of rural areas occurs, expanding the urban mesh of large regions and transforming some territories in their surroundings into anthropized areas. It so happens that this progress requires changes in the natural landscape to meet the basic needs of its inhabitants, which increases proportionally to this development. However, these transformations usually occur without proper planning, favoring the process of local climate change. Given the above, this research aimed to evaluate the environmental conditions that represent different types of occupation in an urbanized rural area, comparing microclimates and representing the characteristics of the environments in a computational algorithm that must assign a classification indicating the quality environmental of these areas. The first part of the research consisted of the collect data experiments that was carried out in the city of Dourados - MS at Unit II of the Federal University of Grande Dourados (UFGD). Considering different types of surface coverage, the climatic elements temperature and relative air humidity were collected during 40 days of winter (cold) and 40 days of summer (heat), using an automatic Datalogger Wireless data acquisition system in 9 microenvironments and an INMET database. The data were later converted into the Temperature and Humidity Index (THI). The THI values made it possible to classify the environments according to the ranges related to the comfort zones for different microclimates. The second part of the study consisted of developing a logical-mathematical model involving an Artificial Neural Network of the scenario created to classify the studied environment according to the human well-being index (HWBI) on a scale ranging from very bad to very good. The proposed neural network has an input layer with twelve neurons, a hidden layer with eighteen neurons, and an output layer with five neurons. The elaborate artificial neural network proved efficient in its training phase, where it corresponded to values of approximately 90% of precision, and in the test phase, to an average precision of 80%. However, the fact that the HWBI is correlated with the THI influenced the development of a second algorithm proposal removing the referent neuron. This change led to the need to change the network parameters in order to obtain its best performance. Even with all the empirical adjustments performed, the accuracy of the network was 62%. As it is the first complex architecture built for multiclass indication of local environmental comfort, it can be concluded that the algorithm well reflected the studied environments involving the interaction of natural resources and built spaces.

Keywords: Environmental comfort; Rural exodus; Semantic segmentation.

LISTA DE FIGURAS

Figura 1 - História da mudança da temperatura global e causas do aquecimento recente	8
Figura 2 - Variações do índice de bem-estar humano (IBEH)	17
Figura 3 - Modelo de um neurônio artificial não linear (Perceptron)	19
Figura 4 - Representação de uma MLP	20
Figura 5 - Diagrama em blocos da aprendizagem supervisionada	23
Figura 6 - Representação Feed-Forward (Entrada) e Feed-backward (Erro)	28
Figura 7 - Ground truth de imagem RGB do Dataset Cityscapes - Anotações finas	34
Figura 8 - Ground truth de imagem RGB do Dataset Cityscapes - Anotações grosseiras	34
Figura 9 - Localização geográfica e experimental.....	36
Figura 10 - Área da Unidade II - UFGD no ano de 2004.....	37
Figura 11 - Área da Unidade II - UFGD no ano de 2020.....	37
Figura 12 - Diagrama esquemático da arquitetura da rede	42
Figura 13 - ITU's médios dos ambientes em função das horas – Verão	47
Figura 14 - ITU's médios dos ambientes em função das horas - Inverno	48
Figura 15 - Erro e acurácia da rede na fase de treinamento	56
Figura 16 - Erro e acurácia da rede na fase de teste	57
Figura 17 - Erro e acurácia da rede - pré-treinamento.....	58
Figura 18 - Acurácia da Rede - Teste	59
Figura 19 - Validação cruzada do erro de entropia cruzada k-fold	60

LISTA DE TABELAS

Tabela 1 - Propriedades radiantes de alguns materiais.....	6
Tabela 2 - Albedo de alguns materiais	6
Tabela 3 - Absortividade de alguns materiais	7
Tabela 4 - Escalas espacial e temporal do clima	10
Tabela 5 - Índices de conforto térmico utilizados em ambientes externos.....	15
Tabela 6 - Intervalos de conforto térmico do ITU.....	17
Tabela 7 - Estudos em Redes Neurais Artificiais	30
Tabela 8 - Estudos em Redes Neurais Artificiais na Agricultura.....	31
Tabela 9 - Estudos em Visão Computacional.....	33
Tabela 10 - Classes de cores utilizadas na segmentação das imagens	41
Tabela 11 - Parâmetros projetados na rede.....	43
Tabela 12 - Escala da classificação de conforto e conversão das classes da camada de saída.....	44
Tabela 13 - Parâmetros corrigidos projetados na rede	45
Tabela 14 - Classificação dos microambientes para a situação de verão	46
Tabela 15 - Classificação dos microambientes para a situação de inverno.....	46
Tabela 16 - Resumo da análise de variância para a avaliação das estações verão e inverno ...	49
Tabela 17 - Médias de ITU para as estações verão e inverno	49
Tabela 18 - Resumo da análise de variância para a avaliação dos microambientes - Verão....	49
Tabela 19 - Resumo da análise de variância para a avaliação dos microambientes - Inverno ..	50
Tabela 20 - Médias de ITU para o verão	50
Tabela 21 - Médias de ITU para o inverno.....	51
Tabela 22 - Equações ajustadas para o ITU no verão.....	52
Tabela 23 - Equações ajustadas para o ITU no inverno	52
Tabela 24 - Segmentação semântica das imagens e as porcentagens das classes	53
Tabela 25 - Classes retornadas pela Rede Neural na fase de teste	62

LISTA DE ABREVIACÕES E SÍMBOLOS

APP's	Áreas de Preservação Permanente
CEPEA	Centro de Estudos Avançados em Economia Aplicada
CH ₄	Gás Metano
CNA	Confederação da Agricultura e Pecuária do Brasil
CNN	Neural Network Convolucional
CO ₂	Dióxido de Carbono
CV	Cross Validation
°C	graus Celsius
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
ET	Effective Temperature
°	graus
g/cm ³	gramas por centímetro cúbico
h	hora
IBEH	Índice de Bem Estar Humano
IBGE	Instituto Brasileiro de Geografia e Estatística
INMET	Instituto Nacional de Meteorologia
INMETRO	Instituto Nacional de Metrologia, Qualidade e Tecnologia
IPCC	Intergovernmental Panel on Climate Change
ITU	Índice de Temperatura e Umidade
K	Kelvin
km	Quilômetros
μ	Micro (10 ⁻⁶)
m	metros
m ²	metros quadrados
PET	Physiological Equivalent Temperature
PIB	Produto Interno Bruto
PMV	Predicted Mean Vote
PT	Perceived Temperature
RGB	Red, Green e Blue
RNA	Redes Neurais Artificiais
SET	Standard Effective Temperature

T	Temperatura
Ts	Temperatura de bulbo seco do ar
UFGD	Universidade Federal da Grande Dourados
UR	Umidade relativa do ar
UTCI	Universal Termal Climate Index
W	Watts
α	absortividade
ε	emissividade do material

SUMÁRIO

RESUMO	iii
ABSTRACT	iv
LISTA DE FIGURAS	v
LISTA DE TABELAS	vi
LISTA DE ABREVIACÕES E SÍMBOLOS	vii
1. INTRODUÇÃO	1
2. REVISÃO BIBLIOGRÁFICA	3
2.1. Êxodo urbano	3
2.2. Tipos de coberturas de superfícies	4
2.3. Mudanças climáticas.....	7
2.4. Clima e escala de estudo	9
2.5. Fatores climáticos	11
2.6. Índices de conforto térmico.....	14
2.7. Inteligência Artificial.....	18
2.7.1. Rede Neural Artificial Profunda	19
2.7.2. Visão Computacional	32
3. MATERIAIS E MÉTODOS	36
3.1. Localização e características da área de estudo	36
3.2. Metodologia	38
3.2.1. Experimento de Campo	38
3.2.1.1. Análise dos dados	39
3.2.3. Segmentação Semântica.....	40
3.2.4. Rede Neural Artificial Profunda	41
4. RESULTADOS E DISCUSSÕES	46
4.1. Estatística experimental	48
4.2. Segmentação Semântica dos microambientes	53
4.3. Rede Neural Artificial Profunda	56
4.3.1. Validando a rede neural - Resultados sem o ITU.....	58
5. CONCLUSÃO	66
5.1 Sugestões para trabalhos futuros	67
6. REFERÊNCIAS BIBLIOGRÁFICAS	68

ANEXO 1 - Script utilizado na extração das características dos elementos paisagísticos das imagens RGBs convertidas em <i>Ground Truth</i>	77
ANEXO 2 - Script 1 da Rede Neural Artificial	86
ANEXO 3 - Script 2 da Rede Neural Artificial	93

1. INTRODUÇÃO

O agronegócio brasileiro segue em forte ritmo de desenvolvimento, e vem mostrando o quanto tem fortalecido a economia nacional ao longo dos anos. Para Smalci et al. (2020) a demanda por alimentos no mundo, impulsionada pelo aumento populacional, permite reconhecer que o Brasil, com sua maior extensão de terras aráveis do mundo e a grande variedade climática e de solos, faz do agronegócio um dos setores econômicos mais importantes.

O crescimento de uma região está diretamente ligado ao desenvolvimento econômico local. É neste contexto de desenvolvimento que ocorre a expansão populacional das áreas rurais, expandindo a malha urbana das grandes cidades, e transformando alguns territórios do seu entorno em áreas antropizadas (CATTIVELLI, 2021).

Este fato, junto ao desenvolvimento populacional que também está em constante crescimento, cria, principalmente em autoridades governamentais, uma apreensão mundial quanto à preservação dessas áreas e dos recursos naturais ainda disponíveis, o que tem elevado o índice de pesquisas voltadas à identificação das principais causas geradoras e quais as suas implicações com esse processo de degradação do meio ambiente.

Aliado a estes desenvolvimentos está a consequente degradação da vegetação para construção de edificações que atendam às necessidades humanas, geradas por este crescimento. O consequente volume de construções geradas provoca uma elevação nas temperaturas e uma diminuição da umidade do ar (LOVATTO et al., 2020). A imponente das construções também modifica o fluxo natural dos ventos. Também é perceptível a diminuição de vegetação nesses locais, assim como a superfície do solo que quase sempre é revestida por materiais impermeáveis.

De acordo com Ledda; Serra; De Montis (2019), as ações antrópicas provocam múltiplas desordens nas paisagens. Estas ocorrem por meio de intensos procedimentos de substituição das áreas naturais, por diferentes tipos de emprego do solo e da fragmentação dos espaços com cobertura vegetal. Este fato ocorre mundialmente, tanto no meio urbano quanto no rural, e sua extensão tem sido ampliada cada vez mais por meio do desenvolvimento do agronegócio.

Em virtude dessas mudanças ocorridas no meio ambiente devido às ações humanas, o próprio homem tem sentido seus efeitos, principalmente pelas mudanças climáticas ocorridas ao longo dos anos. Embora a importância do clima no planejamento de uma área urbanizada seja reconhecida, constata-se que muito pouco desse conhecimento sobre climatologia vem

sendo utilizada no planejamento e na tomada de decisão sobre o uso e ocupação do solo (DOHERTY; KLIMA; HELLMANN, 2016).

Diante disto a preocupação com as ações antrópicas torna-se imprescindível para a conservação e avanço da sociedade, sendo um dos fatores mais importantes na construção de um modelo de desenvolvimento sustentável capaz de determinar o comportamento apropriado a seguir. Porém, a incerteza sobre essas casualidades climáticas dificulta o planejamento e a tomada de decisão quanto ao uso e ocupação dessas áreas.

Entretanto, nos últimos anos tem se observado o desenvolvimento de processos industriais cada vez mais complexos, onde o desenvolvimento de tecnologias que norteiem a tomada de decisões tornou-se um fator decisivo para a inserção e manutenção de um produto ou serviço no mercado moderno. Neste âmbito, Melumad et al. (2020) afirmam que a modelagem matemática aliada a simulação de cenários merece especial destaque, tendo em vista as múltiplas finalidades as quais se destina.

Para os autores a teoria de Redes Neurais Artificiais (RNAs) representa uma dessas alternativas pois elas se diferem dos algoritmos tradicionais que empregam métodos determinísticos, usando um método de treinamento probabilístico. A utilização de redes neurais torna-se cada vez mais uma opção atrativa, haja vista a atual ampliação da sua capacidade computacional.

Como forma de contribuir com os estudos de ambiência e climatologia, é proposto como objetivo geral desta pesquisa, avaliar as condições ambientais que representem diferentes tipos de ocupação em uma área rural urbanizada, comparando microclimas, e representando as características do ambiente em um algoritmo computacional que deve atribuir uma classificação indicando a qualidade de ambiência dessa área.

Os objetivos específicos consistem em traçar perfis de possível conforto e desconforto ambiental em função da ocupação do solo e o tipo de superfície dos locais avaliados em função do período do ano; analisar as características das áreas através da segmentação semântica das imagens dos microambientes estudados; elaborar, treinar e testar um algoritmo de programação que represente e classifique o cenário estudado utilizando RNA.

Desta maneira, este trabalho buscou subsidiar as pesquisas do clima e ambiência quanto a aplicação de modelos matemáticos que possam auxiliar na manutenção e na tomada de decisão de planejamento para uso e ocupação de áreas rurais antropizadas.

2. REVISÃO BIBLIOGRÁFICA

2.1. Êxodo urbano

O Instituto Brasileiro de Geografia e Estatística em seu relatório anual destaca que o estado de Mato Grosso do Sul possui uma superfície de 357.147,994 km², participando com 22,2% da superfície da região Centro-Oeste e 4,2% da área territorial brasileira (de 8.514.876 km²) (IBGE, 2021).

No Mato Grosso do Sul a área total de ocupação agrária é de 35.712.496 milhões de hectares, 30.549.179 mil estabelecimentos agropecuários, sendo que 15.727.930 são ocupados por pastagens cultivadas, 2.400.000 hectares de área agrícola e silvicultura, 9.503.082 hectares de área preservada (unidades de conservação e pastagens nativas), 1.293.822 hectares de área ocupada por indígenas e assentamentos rurais e 6.787.662 hectares compreendendo as áreas urbanas, estradas, rios, APP'S e reserva legal (IBGE, 2021).

O agronegócio sempre esteve em posição de destaque nos debates econômicos e nas grandes pautas de discussões no país, devido a sua capacidade de expansão de produtividade e geração de empregos. Para se ter uma ideia o PIB brasileiro cresceu 1% em 2017, enquanto o PIB-volume do Agronegócio, calculado pelo CEPEA/CNA, aumentou 7,2% – impulsionado por uma produção recorde “dentro da porteira”, pela importante recuperação agroindustrial e principalmente pela consequente expansão desses crescimentos sobre o setor de serviços (IBGE, 2017).

Juntamente com este desenvolvimento ocorre a expansão das áreas urbanas rurais com o aumento da população residente no campo. Segundo Laurenti (2013) está havendo um processo de fixação e urbanização rural, devido ao crescimento de ocupações agrícolas e não agrícolas. Entretanto o início dessa expansão geralmente se dá de forma descontrolada, sem um planejamento adequado, avançando por territórios que deveriam ser preservados. Isso se deve à falta de um plano diretor que assegure o bem-estar geral e garanta um desenvolvimento urbano sustentável para essas regiões em desenvolvimento.

Há tempos ouve-se muito falar em êxodo rural, o que é conceituado como o processo de migração dos habitantes do campo para as cidades. Entretanto Almeida (2020) tem estudado os motivos da migração da área urbana para a rural, o que ela intitulou como *Fugere Urbem* no Século 21, expressão em latim que significa “fugir da cidade”. Para a autora o que tem levado a migração das grandes cidades para áreas rurais geralmente está relacionada com as oportunidades de emprego advindas do agronegócio, bem como a busca por uma melhor qualidade de vida.

Entretanto Laurenti (2013) afirma que essa relação do homem com a natureza sempre foi repleta de conflitos, e nem sempre o homem se preocupou em compreender essa relação. A interferência humana nos sistemas ambientais na busca pelo crescimento socioeconômico tem causado graves danos ao meio ambiente e consequentemente a própria humanidade.

Para Martins (2015) a atividade humana sem conhecimento dos recursos naturais disponíveis, à falta de planejamento no uso e ocupação do solo, o uso de sistemas não adequados de manejo, associada ao desmatamento incorreto e a exploração do solo acima de sua capacidade (superpastoreio, agricultura extensiva), dão origem a uma sequência de mudanças nas propriedades e natureza do solo, tornando-o mais susceptível às forças naturais de degradação, estes fatos somados as mudanças climáticas ocorridas em microescala, exercem influência significativa nos elementos climáticos e consequentemente no nível de conforto dos habitantes.

2.2. Tipos de coberturas de superfícies

Para que uma pessoa possa sentir conforto térmico em um ambiente existe uma troca de calor entre o corpo e o meio em que ela se encontra. Para Frota; Shiffer (2001) essas trocas são regidas pelas leis da física ou ainda por influências do mecanismo de adaptações fisiológicas, pelas condições ambientais e por fatores individuais.

Devido aos avanços em infraestrutura ocasionados pela urbanização de grandes áreas, a paisagem natural desses ambientes é completamente modificada. Objetivando o propósito de ter uma área que gere conforto e qualidade aos acessos locais, muitas mudanças interferem no microclima desses espaços. Ribeiro (2016) afirma que uma das principais mudanças é a alteração das coberturas das superfícies.

Existem diversos tipos de superfícies utilizadas em áreas urbanizadas, estas podem ser de origem natural ou artificial. Para melhorar a circulação da área, opta-se quase que exclusivamente por superfícies que sejam impermeáveis. Sendo que, notadamente, as superfícies artificiais impermeáveis interferem de forma significativa no clima local (RIBEIRO, 2016).

Essas alterações nas características térmicas das superfícies, aliadas a presença de edificações e materiais de construção quando comparadas as áreas verdes são as modificações mais importantes associadas ao processo de urbanização de uma área, pois estes aumentam a absorção de energia e a emissão de radiação absorvida (ROMERO, 2007).

Ainda segundo Romero (2007), os materiais artificiais utilizados como coberturas de superfícies possuem capacidade térmica mais elevadas e são melhores condutores de calor que os de origem natural. Além disso, as superfícies externas das edificações também contribuem de forma significativa para este fato atuando como refletores e radiadores que, em conjunto com os pavimentos, aumentam os efeitos da radiação incidente.

Para Oliveira (2008) os diferentes tipos de coberturas do solo definem as trocas de energia que ocorrem entre a superfície da Terra e a atmosfera, portanto sendo um dos principais determinantes do microclima local.

Entretanto Mascaró; Mascaró (2005) afirmam que outros determinantes devem ser considerados no estudo do microclima, pois o desempenho do recinto também está influenciado pelas propriedades termo-físicas dos materiais presentes nas áreas, como por exemplo a arborização local, edificações, tipo e coloração do material etc. Oliveira (2011) confirma este fato ao declarar que uma área sombreada é fracamente atingida pela radiação solar direta incidente e, assim, a temperatura radiante daquela superfície é menor, o que diminui a radiação de ondas longas emitidas.

O microclima de uma região urbanizada está relacionado com o balanço de energia dos materiais que compõem sua superfície, estes que são capazes de alterar significativamente os elementos climáticos. Segundo Alves; Vecchia (2012), a temperatura do ar está correlacionada com a temperatura superficial, esta constatação pode ser verificada pela lei de Stefan-Boltzmann. Onde todo corpo com temperatura acima de 0K emite energia radiativa, segundo esta lei a densidade de fluxo de energia (E) em (W/m^2) é proporcional à quarta potência de sua temperatura absoluta (T) em (K) (Equação 1).

$$E = \varepsilon \sigma T^4 \quad (1)$$

Onde ε é o poder emissivo do corpo, ou seja, a emissividade; σ é a constante de Stefan-Boltzmann ($= 5,67.10^{-8} Wm^2K^4$). Para a maioria dos objetos naturais, o poder emissivo varia entre 0,9 e 1,0, na Tabela 1 estão relacionados os materiais tipicamente utilizados na constituição de um meio urbanizado. A emissividade é a capacidade que os materiais possuem de emitir a radiação absorvida (ALVES; VECCHIA, 2012).

Tabela 1 - Propriedades radiantes de alguns materiais

Superfície	Emissividade (ϵ)
Solos	0,90 – 0,94
Gramma	0,90 – 0,95
Floresta	0,97 – 0,99
Água	0,85 – 0,95
Concreto	0,90 – 0,96
Asfalto	0,95
Tijolo	0,90 – 0,92
Rocha	0,85 – 0,95
Cascalho	0,92
Cerâmica	0,90

Fonte: Alves; Vecchia (2012)

Outro componente importante do balanço de radiação, é o albedo, para Cunha (2012) o albedo é igual a razão entre a radiação eletromagnética refletida pela superfície e a incidente. Como ele sofre variações durante o ano, a quantidade de energia disponível na superfície sofre variações. Dessa forma, a temperatura na superfície pode variar junto com esta grandeza.

Diferentes tipos de revestimentos de superfícies e materiais utilizadas no processo de urbanização possuem albedos diferentes e suas propriedades termo físicas influenciam fortemente na qualidade térmica das áreas urbanizadas (OLIVEIRA, 2011). Como no ambiente urbanizado que há uma grande heterogeneidade de materiais, como telhado, pintura, asfalto, calçada, concreto, grama e árvores, o albedo apresenta diversos valores (Tabela 2).

Tabela 2 - Albedo de alguns materiais

Superfície	Albedo
Solos	0,05 – 0,40
Gramma	0,16 – 0,26
Floresta	0,13 – 0,23
Água	0,08 – 0,10
Concreto	0,10 – 0,35
Asfalto	0,05 – 0,20
Tijolo	0,20 – 0,40
Rocha	0,20 – 0,35
Cascalho	0,08 – 0,18
Cerâmica	0,10 – 0,35

Fonte: Alves; Vecchia (2012)

O albedo é a relação entre a radiação solar incidente e a refletida, seu valor está entre 0 e 1. Em geral, superfícies secas e de cores claras refletem mais radiação que superfícies úmidas e escuras, (BRAGA et al., 2009). Assim sendo, uma superfície de albedo 0,5 indica que ela é capaz de refletir metade da energia solar que incide sobre ela.

Para Oliveira (2011) os materiais que possuem albedo baixo e condutividade alta proporcionam um microclima suave e estável, enquanto o inverso contribui para a criação de um microclima de extremos.

O Albedo e a emissividade dos materiais estão diretamente relacionados à sua absorptividade. Silva (2019) afirma que uma das principais determinantes desta propriedade está na cor superficial dos materiais construtivos que são seletivos à radiação solar (onda curta). Este conceito tange a propriedade de absorptividade (α). Por exemplo, se em uma superfície de revestimento asfáltico, a radiação solar absorvida for de 85%, significa que 15% serão refletidas para o meio externo (Tabela 3).

Tabela 3 - Absortividade de alguns materiais

Superfície	Absortividade (α)	
Concreto aparente	0,65 / 0,80	
Telha de barro	0,75 / 0,80	
Tijolo aparente	0,65 / 0,80	
Reboco claro	0,30 / 0,50	
Revestimento asfáltico	0,85 / 0,98	
Vidro incolor	0,06 / 0,25	
Vidro colorido	0,40 / 0,80	
Vidro metalizado	0,35 / 0,80	
Pintura	Branca	0,20
	Amarela	0,30
	Verde clara	0,40
	“Alumínio”	0,40
	Verde escuro	0,70
	Vermelha	0,74
	Preta	0,97

Fonte: Silva (2019) adaptado

2.3. Mudanças climáticas


O Painel Intergovernamental de Mudanças Climáticas (do inglês IPCC: *Intergovernmental Panel on Climate Change*), refere-se à Mudança climática como uma

“variação estatisticamente significativa nas condições médias do clima ou em sua variabilidade, que permanece por um longo período. Esta pode advir de processos naturais, ou ainda de mudanças antropogênicas persistentes na composição da atmosfera ou no uso do solo (IPCC, 2014)”.

Ainda segundo o relatório do IPCC (2014), as mudanças nas temperaturas globais estão sendo ocasionadas por atividades humanas. Essas mudanças ocorridas nas temperaturas globais têm seu início em pequenas escalas, como por exemplo a micro.

Existe um significativo debate sobre desenvolvimento, população e ambiente quando se trata das mudanças climáticas e ambientais. As regiões que mais crescem no país têm uma forte expansão no agronegócio (Gomes, 2019), entretanto as mudanças na forma de uso e nas coberturas do solo dela decorrentes vêm produzindo uma série de impactos negativos ao ambiente e à população.

Segundo o relatório do IPCC/AR6 (2021), a influência humana aqueceu o clima a uma taxa sem precedentes pelo menos nos últimos 2.000 anos. Na Figura 1 pode ser observado as mudanças na temperatura global da superfície em relação ao período de 1850 a 1900.



Fonte: IPCC (2021)

Figura 1 - História da mudança da temperatura global e causas do aquecimento recente

Na Figura 2a pode ser observado as mudanças na temperatura da superfície global reconstruída a partir de arquivos paleoclimáticos (linha cinza sólida, 1–2000) e de observações diretas (linha preta sólida, 1850–2020), ambas medidas decadalmente em relação a 1850–1900. A barra vertical à esquerda mostra a temperatura estimada (faixa muito provável) durante o

período mais quente de vários séculos, pelo menos nos últimos 100.000 anos, que ocorreu por volta de 6.500 anos atrás, durante o atual período interglacial (Holoceno). Esses últimos períodos quentes foram causados por variações orbitais lentas (multimilenares). O sombreado cinza com linhas diagonais brancas mostra prováveis reconstruções dos intervalos de temperatura (IPCC/AR6, 2021).

Na Figura 2b observa-se as mudanças na temperatura da superfície global nos últimos 170 anos (linha preta) em relação à média anual de 1850-1900, em comparação com as simulações do modelo climático CMIP6. Resposta da temperatura a fatores humanos e naturais (marrom), e apenas a fatores naturais (verde). As linhas de cores sólidas mostram a média do modelo múltiplo e os tons coloridos mostram a faixa muito provável de simulações (IPCC/AR6, 2021).

Se esses cenários de mudanças climáticas previstos pelo IPCC se confirmarem no futuro, um dos setores mais afetados será o agronegócio, pois eles são diretamente influenciados pelos elementos climáticos (MATA; FONSECA; MIRANDA, 2018). Segundo as autoras ainda que o agronegócio fosse uma atividade com grande capacidade de adaptação às mudanças climáticas, ocorrendo num intervalo de décadas, os eventos meteorológicos extremos afetarão qualquer tipo de negócio.

Para os autores do relatório do IPCC/AR6 (2021) uma proposta de solução para a mitigação das mudanças climáticas são, do ponto de vista da ciência física, limitar o aquecimento global induzido pelo homem a um nível específico requerendo a limitação das emissões cumulativas de CO₂, atingindo pelo menos as emissões de CO₂ a zero líquido, juntamente com fortes reduções em outras emissões de gases de efeito estufa. Reduções sustentadas nas emissões de CH₄ (metano) de forma rápida e forte também limitariam o efeito de aquecimento resultante do declínio da poluição por aerossol e melhoraria a qualidade do ar.

Todavia, mesmo com todos os avanços teóricos e práticos já ocorridos, o ritmo de degradação ambiental continua devido ao crescimento demográfico e econômico, pois para uma população global que se aproxima de 8 bilhões de habitantes, a tendência de consumo em bens e serviços deve ser cada vez maior, demandando recursos ecossistêmicos além da capacidade de regeneração dos recursos naturais disponíveis na Terra (FERREIRA; LOPES, 2020).

2.4. Clima e escala de estudo

Clima, segundo Mano; Pacheco; Bonelli (2010) é o conjunto de condições meteorológicas caracterizada pelo estado médio da atmosfera em um dado ponto da superfície

terrestre. Este pode ser frio, glacial, continental, marítimo, desértico, árido, semiárido, quente, tropical, subtropical, temperado etc.

Para definir o clima das diversas regiões do planeta, estas são divididas por suas características similares, as quais são chamadas regiões climáticas. Segundo Cavalcanti et al. (2009) no Brasil vários tipos diferentes de clima são identificados, dada a sua grande extensão territorial e a sua localização entre dois trópicos.

Através do processo de urbanização são ocasionadas modificações no ambiente natural local, variações dos elementos meteorológicos, criando um clima típico de ambientes artificiais chamado de clima urbano (ROTH, 2007).

O clima pode ser estudado por meio de duas dimensões, a espacial e a temporal, e ambas são aplicadas de forma conjunta. De acordo com Mendonça; Danni-Oliveira (2007) as escalas espaciais mais conhecidas são as macroclimática, mesoclimática e microclimática; já as escalas temporais mais utilizadas são as escalas geológica, histórica e contemporânea, conforme pode ser observado na Tabela 4.

Tabela 4 - Escalas espacial e temporal do clima

Ordem de grandeza	Subdivisões	Escala Horizontal	Escala Vertical	Temporalidade das variações mais representativas	Exemplificação espacial
Macroclima	Clima global Clima zonal Clima regional	> 2.000 km	3 a 12 km	Algumas semanas a vários decênios	O globo, um hemisfério, oceano, continente etc.
Mesoclima	Clima regional Clima local Topoclima	2.000 km a 10 km	12 km a 100 m	Várias horas a alguns dias	Região natural, montanhas, cidades etc.
Microclima		10 km a alguns m	Abaixo de 100 m	De minutos ao dia	Bosque, uma rua, uma edificação/casa etc.

Fonte: Mendonça; Danni-Oliveira (2007)

Para Mendonça; Danni-Oliveira (2007) as definições das escalas são:

Macroclima: é definido como a maior das unidades climáticas compreendendo áreas muito extensas da superfície da Terra. Seu domínio vai desde o Planeta (clima global), estendendo-se por faixas ou zonas (clima zonal), até amplas regiões (clima regional).

Mesoclima: é considerado a unidade intermediária entre as escalas de grandeza superior e inferior do clima, dividindo-o em clima regional, local e topoclima.

Microclima: é apontado como a menor unidade da escala climática, sua extensão pode ir de alguns centímetros a algumas dezenas de m², e há autores que consideram até centenas de m².

Para Frota; Schiffer (2001) uma aglomeração em área urbanizada não apresenta, necessariamente, as mesmas condições climáticas relativas ao macroclima regional na qual está inserida. Estas transformações estão relacionadas com a extensão e setores prevaletentes de atividades produzidas na área em estudo.

Diante disto, a escala abordada nesse estudo é a microclimática, considerada por Lima (2014) como a escala de maior detalhe, conseqüentemente de maior aproximação da superfície terrestre. Sua influência pode ser dada pelo tipo de cobertura do terreno, por exemplo, o tipo de vegetação, alta ou baixa, vegetação densa ou rala, presença de cobertura morta (*mulching*) sobre o solo, que condiciona um ambiente diferente e especial.

2.5. Fatores climáticos

Os fatores climáticos são definidos pelos atributos físicos que caracterizam as propriedades da atmosfera geográfica de um local. Segundo Ribeiro (2016) os elementos climáticos são aqueles que representam os valores relativos a cada tipo de clima, ou seja, a temperatura, a umidade relativa, as precipitações e a radiação. Para a autora o conhecimento dos fenômenos climáticos são fundamentais para a compreensão do complexo sistema clima - ambiente.

Temperatura do ar - Segundo Lima (2014) a temperatura do ar é definida como uma medição da energia cinética média (movimento) de moléculas individuais na matéria. Para ela temperatura e calor estão relacionados porque as mudanças de temperaturas são causadas pela absorção ou emissão (ganho ou perda) de energia cinética.

Christopherson (2012) considera a latitude, altitude, elevação, nebulosidade e diferenças de aquecimento entre terra e água como principais influenciadores sobre as temperaturas.

Para Vianello; Alves (2000), a variação diária da temperatura do ar está diretamente relacionada com a chegada de energia solar e conseqüentemente o aquecimento da superfície.

Ao longo das 24h diárias a temperatura na superfície varia bastante devido ao movimento de rotação. De acordo com Franco (2010) geralmente o período mais quente é o início da tarde, quando o Sol está perto do alto do céu e a superfície já recebeu toda radiação da

manhã. Já o final da madrugada é normalmente o período mais frio, devido ao Planeta perder calor durante toda a noite.

Para Nince (2009) a temperatura média do ar tem relação direta com a intensidade de radiação solar recebida e a cobertura de nuvem para determinado momento. Pois as nuvens são capazes de modificar o balanço energético local, interceptando o fluxo de radiação infravermelha emitida e o fluxo incidente. Entretanto, se o céu estiver limpo, a superfície recebe energia solar, mas também perde energia por irradiação mais do que com céu encoberto.

De acordo com Miranda et. al (2018), as alterações climáticas resultantes das atividades humanas devem ser avaliadas em função da magnitude e abrangência dos impactos e modificações no clima, tornando, dessa forma, necessário a caracterização dos controles climáticos de macro à microescala.

O termômetro é o instrumento usualmente utilizado para monitorar as variações da temperatura do ar, que podem ser de vários tipos, quais sejam termômetros de máxima e mínima, termômetro de globo, termógrafo, entre outros, cada um específico para o tipo de avaliação que se deseja fazer. Celsius, Fahrenheit e Kelvin (ou absoluta) são as escalas mais utilizadas (FRANCO, 2010).

Umidade relativa do ar – Frota; Schiffer (2001) definem a umidade relativa como a relação da umidade absoluta com a capacidade máxima do ar de reter vapor d'água, àquela temperatura. Tendo que umidade absoluta é o peso do vapor d'água contido em uma unidade de volume de ar (g/cm^3). Pode-se afirmar, desta forma, que a umidade indica quão próximo o ar está da saturação, ao invés de indicar a real quantidade de água.

São inúmeros os fatores que interferem na umidade do ar, dos quais podemos citar a temperatura do ar, urbanização, áreas verdes, lagos, rios, dentre outros. A umidade de um determinado local influencia diretamente na qualidade de vida dos seus habitantes. Nince (2009) confirma esta colocação ao afirmar que a umidade relativa do ar não deve ser inferior a 30%, de forma a evitar o desconforto e problemas que podem ser causadas pelo ressecamento das vias respiratórias. Entretanto, o excesso de umidade também deve ser evitado, de maneira a prevenir a condensação superficial e o desenvolvimento de fungos nos componentes de edificações.

Segundo Varejão (2006) as variações da umidade relativa do ar estão mais relacionadas com a pressão de vapor d'água e com a temperatura do ar. Para ele a marcha semanal da umidade relativa do ar segue uma periodicidade inversa à temperatura, quando a temperatura é máxima a umidade relativa é mínima, e vice-versa.

Para medir a umidade relativa do ar utiliza-se como instrumentos os higrômetros.

Precipitações – A precipitação pluviométrica é uma das variáveis meteorológicas consideradas relevantes para estudos climáticos. Tal importância se deve às consequências que podem ocasionar tanto em seu excesso como sua falta (SANTOS et al., 2021). Segundo Santos e Aquino (2017) precipitação é toda água oriunda da atmosfera que atinge a superfície terrestre, nas formas de chuva, geada, neve, granizo, neblina e orvalho.

Para Franco (2010) a evaporação das águas pluviais é maior nas superfícies impermeáveis, construídas pelo homem (por exemplo, ruas e calçadas), do que nas superfícies cobertas pela vegetação, onde a chuva é absorvida pelo solo.

O pluviômetro é o instrumento utilizado para medir pequenas quantidades de chuva mais precisamente, assim como, para reduzir perdas por evaporação.

Radiação – Para Ribeiro (2016) a radiação é um termo aplicado a todas as formas de fenômenos de ondas eletromagnéticas, mas para a transmissão de calor, só interessam as formas que resultam da diferença de temperatura. Varejão (2006), denomina radiação, ou energia radiante, à energia que se propaga sem necessidade da presença de um meio natural.

Frota; Schiffer (2001) afirmam que a radiação solar é uma energia eletromagnética, de onda curta, que atinge a Terra após ser parcialmente absorvida pela atmosfera. A maior influência da radiação solar é na distribuição da temperatura do globo. As quantidades de radiação variam em função da, latitude, altitude e época do ano.

A energia solar que chega até a superfície terrestre é a radiação solar sob a forma de ondas magnéticas, esta varia de intensidade à medida que penetra na atmosfera. O espectro eletromagnético é subdividido em três faixas: ultravioleta, visível e infravermelho (VAREJÃO, 2006).

Duffie; Beckman (1980) ainda separam radiação em quatro tipos, quais sejam:

a) Radiação direta: aquela recebida do Sol sem ter sido espalhada de alguma forma pela atmosfera;

b) Radiação difusa: é a radiação que teve sua direção alterada por elementos presentes na atmosfera;

c) Radiação de onda curta: tem seu espectro compreendido entre 300 μm e 3000 μm , e inclui os componentes direto e difuso;

d) Radiação de onda longa: tem em seu espectro valores acima de 3000 μm e sua origem em fontes com temperaturas próximas ao ambiente.

O instrumento utilizado para a medição da radiação solar global é o Piranômetro, que quantifica e registra o total de radiação solar global que chega em superfície.

2.6. Índices de conforto térmico

Segundo Frota; Schiffer (2001), a partir dos fatores climáticos é possível desenvolver uma série de estudos que procuram determinar as condições de conforto térmico e os vários graus de conforto ou desconforto por frio ou calor de determinados ambientes.

Nos últimos anos tem sido crescente o número de pesquisas que analisam o conforto térmico de ambientes. Seu estudo destina-se à melhoria térmica de espaços já existentes e ao planejamento de novos espaços. Independentemente da função desempenhada aos espaços, sabe-se que o conforto térmico que ele proporciona é fundamental para a qualidade e o comportamento das pessoas. Assim como espaços urbanizados bem planejados melhoram o clima e a imagem local e encorajam o planejamento de novas áreas (ROSSI; KRUGER; NIKOLOPOULOU, 2011).

O conforto térmico ambiental é resultado das características climáticas de um local, que leva em consideração uma série de fatores que interferem de maneira significativa na expressão microclimática desses espaços (LIMA, 2017). Sendo assim, estudiosos desenvolveram os chamados índices de conforto térmico, agrupando as condições que proporcionem as mesmas respostas. Os índices de conforto térmico buscam abranger em um único parâmetro o efeito conjunto desses elementos.

Segundo Chen; Ng (2011) os primeiros registros de estudos de conforto térmico foram realizados em ambientes internos, o que culminou no desenvolvimento de inúmeros índices capazes de operar quatro parâmetros ambientais – temperatura, umidade, velocidade do vento e temperatura radiante média, além de parâmetros pessoais como, vestimenta e atividade.

Com o passar dos anos e o agravamento das mudanças climáticas, surgiu também a necessidade de se estudar os ambientes externos. Essa necessidade culminou em uma gama de pesquisas e avanços nos números dos índices que pudessem avaliar ambos os ambientes (ROSSI; KRUGER; NIKOLOPOULOU, 2011).

Nas últimas décadas Chen; Ng (2011) e Johansson et al. (2014) apresentaram estudos de conforto térmico em áreas externas, mostraram diversas pesquisas em cidades de diferentes climas. Além disso, os trabalhos mostram a diversidade de índices de conforto criados para avaliação de ambientes internos e externos. Os autores salientam a importância para a necessidade de normas e manuais para melhorar a aplicação e comparação dos estudos na área de conforto ambiental.

Johansson et al. (2014) apresentam os índices de conforto térmico mais utilizados em estudos de áreas externas, apesar de alguns deles terem sido desenvolvidos para aplicação em ambientes internos (Tabela 5).

Tabela 5 - Índices de conforto térmico utilizados em ambientes externos

Índice	Descrição	Referências
Voto Médio Predito (PMV)	Principalmente para espaços internos; variáveis meteorológicas consideradas no conforto térmico (temperatura, umidade, velocidade do vento e temperatura radiante) bem como variáveis pessoais (vestimenta e atividade).	ISO 7730 (2005), ASHRAE (2001), ASHRAE 55 (2010)
Nova Temperatura Efetiva Padrão (SET)		ASHRAE (2001), BLAZEJCZYK et al. (2012)
Temperatura Efetiva (ET)	Principalmente para espaços internos, considera apenas quatro variáveis meteorológicas e padroniza a vestimenta e a atividade para sedentária.	ASHRAE (2001), BLAZEJCZYK et al. (2012)
Temperatura Percebida (PT)	Baseada na equação do PMV, porém muito utilizada em áreas externas.	VDI 3787 (2008), BLAZEJCZYK et al. (2012)
Temperatura Fisiológica Equivalente (PET)	Elaborada para ambientes externos; considera apenas quatro variáveis meteorológicas e padroniza a vestimenta e a atividade.	HÖPE (1999), VDI 3787 (2008), BLAZEJCZYK et al. (2012)
Índice Térmico de Clima Universal (UTCI)	Elaborada para ambientes externos; não necessita de informações de vestuário. Entretanto é dada sob a combinação das variáveis climáticas (vento, radiação, umidade e temperatura do ar).	BLAZEJCZYK et al. (2012), HAVENITH et al. (2011), NINCE et al. (2013)

Fonte: Johansson et al. (2014) adaptado

Para Buriol et al. (2015) o ambiente térmico é o efeito das associações dos fatores climáticos radiação solar, temperatura e umidade relativa do ar e velocidade do vento. Entretanto os autores afirmam que a combinação desses elementos e os mecanismos fisiológicos fazem com que o principal condicionante para conforto térmico seja o binômio temperatura e umidade relativa do ar.

Um dos índices de conforto térmico mais citados na bibliografia nacional e internacional é o índice de temperatura e umidade (ITU) de Thom (1959). Contudo, quando analisado em trabalhos anteriores parece haver uma confusão entre os pesquisadores que utilizaram esse índice. Foram encontradas diversas equações diferentes intituladas como índice de temperatura e umidade, o que leva a conclusão de que por se tratar de uma referência antiga poucos tem acesso à equação original. Diante destes fatos optou-se por utilizar, nesta pesquisa, a Equação 2 proposta por Thom e utilizada por Cesca et al. (2021) para avaliação ambiental.

$$ITU = T_s - (0,55 - 0,0055 \cdot UR) \cdot (T_s - 14,5) \quad (2)$$

Em que:

ITU: índice de temperatura e umidade, adm

T_s : temperatura de bulbo seco do ar ($^{\circ}\text{C}$)

UR: umidade relativa do ar (%)

Assim como as pesquisas avançaram e há inúmeros índices de conforto térmico ambiental, existe também uma série de classificações para ambientes, cujos limiares de intervalo consideram os valores dos índices em relação às características dos ambientes estudados, ou ainda a nível de conforto sentido pelas pessoas.


Para a caracterização dos ambientes, conforme os valores dos índices gerados, foi utilizado os limiares das zonas de conforto estabelecidos originalmente por Thom (1959) e utilizados por Wang et al. (2022). Os limiares do ITU e as características equivalentes são apresentados na Tabela 6.

Tabela 6 - Intervalos de conforto térmico do ITU

Faixas	Intervalo do ITU	Características
1	$\leq 5,9$	Resfriamento muito elevado
2	6,0 a 8,9	Resfriamento elevado
3	9,0 a 11,9	Frio
4	12,0 a 14,9	Desconforto ao frio
5	15,0 a 17,9	Leve desconforto ao frio
6	18,0 a 20,9	Limite inferior da zona de conforto
7	21,0 a 23,9	Centro da zona de conforto
8	24,0 a 26,9	Limite superior da zona de conforto
9	27,0 a 29,9	Leve desconforto ao calor
10	30,0 a 32,9	Desconforto ao calor
11	≥ 33	Aquecimento elevado

Fonte: Wang et al. (2022) adaptado

Já o Índice de Bem-Estar Humano (IBEH) permite uma classificação mais direta dos ambientes estudados, levando em consideração o nível de bem-estar experimentado por seus usuários. Eles foram classificados segundo o mesmo conceito apresentado por Yanagi et al. (2012) que o utilizou para avaliação do bem-estar de atividades agrícolas em ambientes insalubres. A classificação utilizada por eles considerou a predição de conforto variando os ambientes entre muito ruim e muito bom (Figura 2).



FONTE: Yanagi, et al. (2012)

Figura 2 - Variações do índice de bem-estar humano (IBEH)

2.7. Inteligência Artificial

A inteligência artificial não é necessariamente nova, seu marco zero foi em 1956 na Conferência de Dartmouth, onde o termo foi registrado pela primeira vez, referindo-se a um novo campo do conhecimento. Antes disso, 1943, Warren McCulloch e Walter Pitts escreveram sobre estruturas de raciocínio artificiais em forma de modelo matemático que imitam o sistema nervoso humano, denominados de lógica de limiar (BARBOSA; BEZERRA, 2020).


Em 1958 Rosenblatt cria o Perceptron, um algoritmo para o reconhecimento de padrões baseado em uma rede neural computacional de duas camadas usando simples adição e subtração. Em 1986 Rumelhart, Hinton e Williams conseguiram criar algoritmos que usavam redes neurais profundas, porém os tempos de treinamento para os sistemas foram considerados impraticáveis no mundo real por pelo menos dois motivos: - o algoritmo de treinamento não era eficiente; e - os computadores tinham pouca capacidade computacional (DATA SCIENCE ACADEMY, 2021),

Todavia somente em meados dos anos 2000, após estudos de Hinton e Salakhutdinov mostrarem como uma rede neural de várias camadas poderia ser pré-treinada uma camada por vez é que foi possível colocar as redes neurais em evidência novamente (DATA SCIENCE ACADEMY, 2021).

Em uma rede neural, basicamente, o neurônio recebe diferentes dados na camada de entrada, processam esses dados e liberam um resultado na camada de saída. O *Perceptron* é a arquitetura mais simples de uma rede neural, possuindo uma única camada (PEIXOTO, 2013).

Braga; Ferreira; Ludermir (2007) definem as Redes Neurais como modelos matemáticos que se assemelham às estruturas neurais biológicas (neurônios) e que têm capacidade computacional adquirida por meio de aprendizado e generalização. Para Sima et al. (2022) a generalização é a capacidade do seu modelo, após ser treinado, digerir novos dados e fazer previsões precisas.

Através do resultado do trabalho do neuroanatomista e psiquiatra Warren McCulloch e do matemático Walter Pitts (McCulloch; Pitts, 1943) surge então o primeiro modelo artificial de um neurônio biológico, o modelo Perceptron (Figura 3).



FONTE: Neto; Bonini (2014)

Figura 3 - Modelo de um neurônio artificial não linear (Perceptron)


O Perceptron é geralmente usado para classificar os dados em duas partes. Portanto também é conhecido como Classificador Binário Linear (SHARMA, 2017).

Atualmente é mais comum usar outros modelos de neurônios artificiais, mas o Perceptron permite uma compreensão clara de como funciona uma rede neural em termos matemáticos (SHARMA, 2017).

Uma rede Perceptron consegue resolver somente funções linearmente separáveis. A rede não consegue gerar um hiperplano em funções linearmente separáveis. O problema é que no mundo real raramente os dados são linearmente separáveis, o que consequentemente faz com que o Perceptron não seja muito útil para atividades práticas (NIELSEN, 2019).

2.7.1. Rede Neural Artificial Profunda

Segundo Soares; Silva (2011) ao introduzir na rede uma camada extra de neurônios, conhecido como “camada intermediária” ou “camada oculta”, e ainda incluir pesos estimados no modelo entre a camada de entrada e a camada oculta, e a camada oculta usar função de ativação não-linear, tal como a função logística, ele torna-se efetivamente um modelo não-linear. O modelo resultante é chamado de Multi Layer Perceptron ou MLP (Figura 4).



FONTE: Ramírez (2022) adaptado

Figura 4 - Representação de uma MLP

Peixoto (2013) afirma que são nos pesos que residem todo o conhecimento obtido pela rede, estes por sua vez, são os parâmetros ajustáveis da rede, mudando e se adaptando conforme o conjunto de treinamento vai sendo apresentado à rede.

Entretanto treinar uma rede neural profunda que possa generalizar bem para novos dados é um problema desafiador. Para Brownlee (2019) um modelo com pouca capacidade não pode aprender o problema, ocorrendo subajustamento do modelo ou *underfitting*, enquanto um modelo com muita capacidade pode aprender muito bem e ajustar demais o conjunto de dados de treinamento, ocorrendo sobreajustamento ou *overfitting*. Ambos os casos resultam em um modelo que não generaliza bem.

Segundo Haykin (2007) o aprendizado de uma rede neural é um processo pelo qual os parâmetros são adaptados pelo processo de estimulação pelo ambiente onde a rede está inserida. Considera-se desta forma que uma rede neural sofre uma adaptação às características intrínsecas de um problema, onde se procura abranger um grande espectro de valores associados às variáveis pertinentes. Isto ocorre para que a rede neural possua uma melhoria contínua, encontrando uma boa capacidade de resposta para o maior número de situações possíveis.

De acordo com Haykin (2007) o Perceptron de Múltiplas Camadas tem sido aplicado com sucesso para resolver diversos problemas complexos, através do seu treinamento de forma supervisionada com um algoritmo, conhecido como “algoritmo de retropropagação de erro” (backpropagation). Ainda segundo o autor um MLP tem três características distintas:

1. o modelo de cada neurônio da rede inclui uma função de ativação não-linear;

2. a rede contém uma ou mais camadas de neurônios ocultos, que não fazem parte da entrada ou da saída da rede;

3. a rede exibe um alto grau de conectividade, determinado pelos pesos da rede.

A rede MLP deriva seu poder computacional dessas características juntamente com a habilidade de aprender da experiência do treinamento. Entretanto, essas mesmas características são responsáveis também pelas limitações no estado atual do nosso conhecimento sobre o comportamento da rede, por dois motivos principais: a presença de uma forma distribuída de não linearidade e a alta conectividade da rede tornam difícil a análise teórica de um Perceptron de Múltiplas Camadas; a utilização de neurônios ocultos torna o processo de aprendizagem mais difícil de ser visualizado.

As redes neurais, através de seu treinamento, têm a capacidade de aproximar funções não lineares, mapeando as relações de entrada e saída. Essa habilidade permite modelar um sistema conhecendo apenas os valores de entrada e saída, sem a necessidade de conhecer os parâmetros investigados (SOARES; SILVA, 2011).

De acordo com Peixoto (2013) devido a sua estrutura não linear, as redes neurais podem trabalhar com características mais complexas, que nem sempre é possível com as técnicas tradicionais de estatística. Devido às diferentes possibilidades de conexões entre as camadas de neurônios, muitas estruturas distintas podem ser geradas para uma mesma amostra de dados. Para formação de uma rede é necessário que esta seja dividida em camadas. Usualmente as camadas são divididas em três grupos:

- Camada de entrada: onde os vetores são apresentados à rede;
- Camadas ocultas ou intermediárias: onde maior parte do processamento é executado, e que também são consideradas como extratoras de características; e
- Camada de saída: onde é concluído o resultado e apresentado.

Embora existam inúmeros estudos com aplicação de redes neurais artificiais, não existe um método exato para saber o número de camadas intermediárias, bem como o número de neurônios nesta. Para Mas; Flores (2008) isso é uma questão crítica, uma vez que a seleção da topologia tem um impacto profundo sobre os resultados da classificação.

O desempenho de uma rede neural está diretamente ligado ao número das camadas e dos neurônios, principalmente os ocultos, quanto mais camadas, melhor seria o seu desempenho, pois aumentaria a capacidade do seu aprendizado, melhorando a precisão com que delimita as regiões de decisão. Porém, segundo Peixoto (2013) aumentar o número de camadas intermediárias geralmente se torna inviável devido ao trabalho computacional exigido, além de ter mais chances de ocorrer *overfitting*. Para Stathakis (2009) o número de camadas

intermediárias deve ser a média ponderada do tamanho da camada de entrada e do tamanho da camada saída.

Hecht-Nelsen (1989) afirma que com apenas uma camada intermediária, a partir de dados fornecidos para a rede, é possível calcular uma função arbitrária qualquer. Para ele, a camada oculta deve ter por volta de $2i+1$ neurônios, onde i é o número de variáveis de entrada.

Por outro lado, Lippman (1987) afirma que se houver a necessidade de uma segunda camada intermediária na rede, esta deve ter o dobro de neurônios da camada de saída; no caso de apenas uma camada, esta deverá ter $s(i+1)$ neurônios, onde s é o número de neurônios de saída e i , o número de neurônios na entrada.

Heaton (2015) sugere que o número de neurônios nas camadas ocultas pode ser dado em função da Equação 3.

$$Nh = \frac{Ns}{(\alpha * Ni + No)} \quad (3)$$

Em que:

Ns: é o número da amostra de treinamento,

Ni: é o número de neurônios na camada de entrada,

No: é o número de neurônios na camada de saída e α um fator de escala arbitrário geralmente de 2-10.

Ele também recomenda que os números de neurônios na camada oculta, devem ser de no máximo 2 (duas) vezes o número de neurônios da camada de entrada e no mínimo, maior que os neurônios na camada de saída e menor que os da entrada.

Sheela; Deepa (2013) recomenda o número de neurônios na camada oculta conforme a Equação 4.

$$(4N^2 + 3)/(N^2 + 8) \quad (4)$$

Em que:


N: é o número de neurônios na camada de entrada.

Existem duas propriedades primordiais que tornam uma rede neural eficiente como um neurônio biológico, a primeira é a sua capacidade de aprender a partir de seu próprio ambiente e a segunda de melhorar seu desempenho durante o processo de aprendizagem, mantendo como princípio básico a diminuição dos erros entre a saída desejada e a saída obtida.

Gasparacco et al. (2017) conceitua aprendizagem como sendo um processo pelo qual parâmetros livres são adaptados através de uma estimulação do ambiente no qual a rede está inserida. Apesar de existirem diversos métodos para treinamentos de redes neurais, estes podem ser agrupados em dois principais grupos: a) os aprendizados supervisionados e b) não supervisionados. Há ainda os aprendizados por reforço e por competição, entretanto para redes neurais profundas o método mais utilizado é o aprendizado supervisionado, que possui este nome em função de que tanto as entradas quanto as saídas desejadas são fornecidas à rede durante seu processo de treinamento.

Aprendizado supervisionado - Aprendizagem supervisionada, que também é definida como “aprendizagem com um professor”, é o método desenvolvido com a disponibilização de um usuário que verifica os desvios da rede em relação a um determinado conjunto de dados de entrada (HAYKIN, 2007).

De forma conceitual, o professor (usuário) é considerado como a pessoa detentora do conhecimento sobre o ambiente, representado por um conjunto de entrada-saída (Figura 5). Entretanto, este ambiente ainda é desconhecido pela rede neural de interesse.



FONTE: Haykin (2007) adaptado

Figura 5 - Diagrama em blocos da aprendizagem supervisionada

O tipo de aprendizado da rede varia segundo o tipo de feedback que é dado como parâmetro para seu aprendizado. No aprendizado supervisionado quando são fornecidos os dados de entrada e saída esperada, as respostas podem ser obtidas através de modelos de regressão ou classificação (KOECH, 2020).

Regressão: modelo que estuda a relação entre duas variáveis numéricas. É usado em diversas análises preditivas.

Classificação: modelo utilizado para dizer a qual classe os dados pertencem.

Problemas de classificação geralmente são aqueles que envolvem uma ou mais variáveis de entrada e a previsão de um rótulo de classe. Ainda de acordo com Koech (2020) a classificação que têm apenas dois rótulos para a variável de saída é chamada de problema de classificação binária, enquanto os problemas com mais de dois rótulos são chamados de problemas de classificação categórica ou multiclasse.

Classificação Binária: tarefa de prever um dos dois rótulos de classe para um determinado exemplo.

Classificação Multiclasse: tarefa de prever um de mais de dois rótulos de classe para um determinado exemplo.

São inúmeros os parâmetros considerados na elaboração do algoritmo da rede. Um destes a ser considerado no projeto das redes neurais é a taxa de aprendizagem. O que Murphy (2012) conceitua como parâmetro de ajuste em um algoritmo de otimização que determina o tamanho da etapa em cada interação enquanto se move em direção a um mínimo de uma função de erro.

Determinar uma taxa de aprendizagem ideal para uma rede é um processo considerado complexo. Para Surmenok (2017) se a taxa de aprendizado for baixa, o treinamento será mais confiável, mas a otimização levará muito tempo porque os passos em direção ao mínimo da função de perda são pequenos. Se a taxa de aprendizado for alta, o treinamento pode não convergir ou até divergir. As alterações de peso podem ser tão grandes que pode resultar no aprendizado de um conjunto de pesos abaixo do ideal muito rápido ou em um processo de treinamento instável.

Segundo La Vine (2019) para que isso não ocorra faz-se necessário trabalhar em uma rede o que é chamado de gradiente descendente. Heaton (2015) conceitua três variantes de gradiente descendente:

Descida do gradiente estocástico: Usa apenas um único exemplo de treinamento para calcular o gradiente e atualizar os parâmetros.

Gradiente descendente em lote: Calcula os gradientes para todo o conjunto de dados e executa apenas uma atualização em cada iteração.

Gradiente de descida em minilote: O gradiente do minilote é uma variação da descida do gradiente estocástico em que, em vez de um exemplo de treinamento único, o minilote de amostras é usado. É um dos parâmetros de otimização mais popular.

Outro parâmetro considerado importante a ser ajustado para o treinamento de redes neurais profundas é a função de *backward*, ou seja, a Retropropagação do erro. Esta que

segundo Brownlee (2019) tem a função de ajustar os pesos da rede. Existem muitas funções que podem ser usadas para estimar a perda de uma rede. A escolha da função está diretamente ligada à função de ativação utilizada na camada de saída da rede neural. Para Goodfellow; Bengio; Courville (2016) esses dois elementos estão conectados.

Quanto menor for o erro de uma rede neural, mais precisa ela se tornará. Em suma, pode-se dizer que o seu processo de aprendizado é capaz de ser determinado com a redução da saída da função de erro.

Segundo La Vine (2019) cada ciclo de propagação direta e correção por retropropagação para reduzir esse erro é chamado de época. Heath (2013) conceitua época como sendo uma medida do número de vezes que todos os vetores de treinamento são usados uma vez para atualizar os pesos. Para o treinamento em lote, todas as amostras de treinamento passam pelo algoritmo de aprendizagem simultaneamente em uma época antes que os pesos sejam atualizados.

De acordo com Brownlee (2019) para uma pequena amostra de treinamento, o treinamento com grandes períodos pode sobrecarregar sua rede. Da mesma forma, para grandes conjuntos de dados, você precisa treinar com muitas épocas, de forma que sua rede se generalize para seu conjunto de dados. Entretanto ele sugere que se deve encontrar a melhor correspondência para o tamanho da época do conjunto de dados.

Ainda para Brownlee (2019) quanto maior for o número de rodadas de otimização, menor será o erro nos dados de treinamento; no entanto, pode chegar um ponto em que a rede se ajusta excessivamente aos dados de treinamento e começará a perder desempenho em termos de generalização para dados não relacionados ao treinamento.

Como medida de desempenho para o sistema, pode-se pensar em termos do erro médio quadrado ou da soma de erros quadrados sobre a amostra de treinamento. O sinal de erro é dado pela Equação 5:

$$e(n) = d(n) - z(n) \tag{5}$$

Em que:

d : é a diferença entre a resposta desejada; e

$z(n)$: é a saída da rede (em que o índice n varia no intervalo $n = 1, 2, \dots, N$), e sendo N o número total de exemplos de treinamentos.

A fim de evitar que os valores de erro com sinais positivos anulem os negativos, faz-se o erro quadrático de cada amostra $E(n)$ (Equação 6), levando sempre em consideração todas as saídas da rede.

$$E(n) = \frac{1}{2N_s} \sum_{k=1}^{N_o} [e(n)]^2 \quad (6)$$

Para uma análise geral do treinamento utiliza-se a média dos erros quadráticos das amostras de todo o conjunto de treinamento. Medida esta denominada de $E(t)$ e dada pela Equação 7.

$$E(t) = \frac{1}{N} \sum_{n=1}^N E(n) \quad (7)$$

Em que:

t : é o número de épocas de treinamento.

Uma outra forma de se calcular esse erro é a perda de entropia cruzada. Ela tem sido amplamente usada em estudos com modelos de classificação. O erro de entropia cruzada é definido por Brownlee (2020) como uma medida da diferença entre duas distribuições de probabilidade para uma determinada variável aleatória ou conjunto de eventos.

Ao se trabalhar uma rede neural artificial ou aprendizado de máquina, as funções de erro são usadas para otimizar o modelo durante o treinamento. Quanto menor o erro melhor o modelo. Para Koech (2020) a perda de entropia cruzada é uma função de erro muito importante principalmente para modelos de classificação. Um modelo perfeito tem uma perda de entropia cruzada de 0 (zero).

Para Bishop (2006) usar a função de perda de entropia cruzada em vez da soma dos erros quadráticos para um problema de classificação leva a um treinamento mais rápido, bem como a uma generalização aprimorada.

A definição matemática de perda de entropia cruzada para n classes, é dada conforme a Equação 8 (KOECH, 2020).

$$L_{CE} = - \sum_i^n t_i \log(p_i) \quad (8)$$

Em que:

t_i = rótulo verdadeiro;

p_i = probabilidade da função;

i = classes.

O processamento de cada neurônio da rede se dá pela combinação das entradas aplicadas a uma função de ativação. As principais funções de ativação são:

- **Função Linear:** não altera a saída de um neurônio, sendo geralmente empregada em processos de regressão numérica, em especial na camada de saída (Equação 9) (CARVALHO, 2018).

$$f(x) = ax \quad (9)$$

- **Função Sigmóide:** apresenta um comportamento semelhante ao da função degrau, com a vantagem de apresentar uma curva suave e continuamente diferenciável, o que facilita o processo de treinamento dando direcionamento para a adequação dos pesos sinápticos com base no erro do sistema. Como apresenta valor de saída entre 0 e 1 é bastante empregada em camadas que precisam ter como saída apenas números positivos (Equação 10) (REIS, 2016).

$$f(x) = 1 / (1 + e^{-x}) \quad (10)$$

- **Tangente Hiperbólica:** função semelhante a sigmóide, é uma função escalonada da sigmóide, mantendo as mesmas características, sendo muito aplicada, e com o diferencial de possuir como saída valores entre -1 e 1 (Equação 11) (SCALABRIN, 2019).

$$\text{Tanh}(x) = 2 / (1 + e^{-2x}) - 1 \quad (11)$$

- **ReLU:** Unidade linear retificada (do inglês *Rectified Linear Unit* – ReLU) foi proposta por Nair; Hinton (2010) é a função de ativação mais utilizada nos projetos de redes neurais modernos. Ela tem como objetivo reduzir o tempo de treinamento de redes neurais artificiais profundas sendo aplicada aos neurônios das camadas ocultas (Equação 12) (SCALABRIN, 2019).


$$f(x) = \max(0, x) \quad (12)$$

- **Função Softmax:** também é um tipo de função sigmóide, mas é útil quando se tenta lidar com problemas de classificação. A função sigmóide é capaz de lidar com apenas duas classes. A função softmax transforma as saídas para cada classe para valores entre 0 e 1 e divide pela soma das saídas. Isso essencialmente dá a probabilidade de a entrada estar em uma determinada classe (Equação 13) (DATA SCIENCE ACADEMY, 2021).

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \text{ for } j = 1, \dots, K \quad (13)$$

De acordo com Soares; Silva (2011), uma das redes neurais mais utilizadas é o Perceptron Múltiplas Camadas (MLP) treinada com o algoritmo *backpropagation* (PB) ou retropropagação do erro.

Segundo Haykin (2007) a aprendizagem por retropropagação de erro consiste em dois passos através das diferentes camadas da rede: a) um passo para frente, a *Feed-forward* (a propagação), e b) um passo para trás, *Feed-backward* (a Retropropagação) (Figura 6).



FONTE: Haykin (2007) adaptado

Figura 6 - Representação Feed-Forward (Entrada) e Feed-backward (Erro)

Feed-forward – é um padrão de atividade que se propaga pela rede da camada de entrada até a camada de saída, e conseqüentemente é produzido, como resposta real a rede, um conjunto de saídas. Durante este processo os pesos são todos fixos.

Feed-backward – considera a resposta real obtida na saída e a resposta esperada para produzir um sinal de erro. Durante este processo o erro se propaga na direção oposta ao fluxo

de dados, indo da camada de saída até a primeira camada oculta, ajustando os pesos das camadas.

O algoritmo básico pode ser desenvolvido de duas formas, por aprendizado incremental ou por aprendizado acumulativo. No primeiro, os pesos são atualizados a cada apresentação de um novo padrão, porém ele tende a aprender melhor com o último. No modo acumulativo, os pesos são ajustados somente depois da apresentação de todos os padrões. O que faz com que o aprendizado acumulativo seja o processo de treinamento da rede mais utilizado como tentativa de acelerar o treinamento da rede (PEIXOTO, 2013).

No treinamento e teste de um modelo de rede neural os conjuntos de dados geralmente são ordenados de forma aleatória, o que é considerado uma abordagem comum para os estudiosos da área. Entretanto Rabello (2019) apresenta o método denominado Validação Cruzada k-fold. Este que o autor descreve como o método que dividi a base de dados de forma aleatória em K subconjuntos com aproximadamente a mesma quantidade de amostras em cada um deles. A cada interação, treino e teste, um conjunto formado por k-1 subconjuntos são utilizados para treinamento e o restante para o teste. Esse processo garante que cada subconjunto seja utilizado para teste em algum momento da avaliação do modelo.

Avaliar o algoritmo da rede neural ao final do processo é parte essencial de uma pesquisa. Segundo Mishra (2018) o modelo avaliado pode fornecer resultados satisfatórios quando avaliado usando uma métrica, porém pode fornecer resultados ruins quando avaliado em relação a outras métricas.

Para Pykes (2021) quando se trata de apresentar os resultados experimentais de uma rede neural artificial, existem inúmeras métricas disponíveis, escolher a métrica certa é crucial ao avaliar o desempenho do modelo. Acurácia, Recall, Precisão e F1-score são algumas das métricas mais utilizadas para avaliar o desempenho de um modelo preditivo para tarefas de classificação. A acurácia da classificação talvez seja a métrica mais simples que se possa imaginar, e é definida como o número de previsões corretas dividido pelo número total de previsões .

Por fim, a escolha do modelo de rede que melhor converge com seu banco de dados é uma escolha crucial para estudos envolvendo redes neurais artificiais. Existe uma infinidade de diferentes arquiteturas de redes neurais descritos nas literaturas, tais como, Feed Forward (FF), Recurrent Neural Network (RNN), Redes de função de Base Radial (RBF), Redes de Função Sample (SFNN), Redes de Fourier e Redes Wavelet, estas são usadas para resolver diferentes tipos de problemas, como por exemplo, as redes neurais convolucionais que são amplamente utilizadas em problemas de Visão Computacional ou ainda as redes neurais recorrentes usadas

em problemas de Processamento de Linguagem Natural (DATA SCIENCE ACADEMY, 2021).

Dessa forma, estudos são realizados em diferentes áreas do conhecimento buscando o desenvolvimento de máquinas inspiradas no potencial humano, que sejam capazes de adquirir aprendizado ao longo do tempo e tornar-se adaptável a quase todas as situações (Tabela 7).

Tabela 7 - Estudos em Redes Neurais Artificiais

Estudo	Referências
Procedimento para tornar mais efetivo o uso de Redes Neurais Artificiais em planejamento e transportes	BOCANEGRA (2002)
RNAs na avaliação e predição de valores genéticos para ganho de peso em bovinos de corte de raças zebuínas brasileiras	MEIRELLES (2005)
Sistema hipermídia sobre câncer de colo de útero com interface adaptativa usando Redes Neurais Artificiais MLP	MALINVERNI (2006)
Aplicação de Redes Neurais Artificiais na Construção de Modelos de Fragilidade Ambiental	SPÖRL; CASTRO; LUCHIARI (2011)
Rede neural artificial aplicada à estimativa da pressão de poros de uma formação rochosa	MENDONÇA et al. (2021)

A agricultura tem acompanhado este desenvolvimento, estudos de Kamilaris; Prenafeta-Boldú (2018) apresentam uma revisão de trabalhos na área que utilizaram redes neurais para processamento e análise dos seus dados (Tabela 8).

Tabela 8 - Estudos em Redes Neurais Artificiais na Agricultura

Área	Descrição do problema	Dados usados	Classes e rótulos	Modelo de RNA usado
Classificação de folhas.	Classificação de folhas de diferentes espécies de plantas.	Conjunto de dados Flavia, composto por 1907 imagens de folhas de 32 espécies com pelo menos 50 a 77 imagens por espécie.	32 classes: 32 plantas de espécies diferentes.	Rede Neural Convolucional.
Identificação de ervas daninha.	Classificação de 91 tipos diferentes de ervas daninhas.	Conjunto de dados de 3.980 imagens contendo 91 tipos de sementes de ervas daninhas.	91 classes: Diferentes ervas daninhas encontradas em campos agrícolas comuns. A semelhança entre algumas classes é muito alta (apenas pequenas diferenças na forma, textura e cor).	PCANet.
Classificação da cobertura solo.	Identificação de 13 diferentes tipos de coberturas do solo em KSC e 9 diferentes tipos em Pavia.	Um local de vegetação mista sobre Kennedy Centro Espacial Kennedy (KSC), Flórida, EUA (conjunto de dados 1), e uma área urbana sobre a cidade de Pavia, Itália (conjunto de dados 2). Conjuntos de dados hiperespectrais.	13 classes diferentes de cobertura do solo (Conjunto de dados 1), 9 classes de cobertura do solo com árvores (conjunto de dados 2): solo, prado, água, sombras, diferentes materiais.	Híbrido de PCA e autocodificador (AE).
Classificação da cobertura solo.	Classificação de Cobertura do solo considerando séries temporais.	O primeiro conjunto de dados gerado usou uma série temporal de imagens Pléiades VHSR na Bacia THAU. O segundo foi gerado a partir de uma série temporal de 23 imagens Landsat 8 adquirido em 2014 na Ilha da Reunião.	11 classes (conjunto de dados 1), 9 classes (conjunto de dados 2). Tipos de cobertura do solo como árvores, plantações, florestas, água, solos, áreas urbanas, pastagens etc. (Objeto de imagem ou pixel).	One-unit STM,

Fonte: Kamilaris; Prenafeta-Boldú (2018) adaptado

2.7.2. Visão Computacional

A Visão Computacional também é um campo da Inteligência Artificial. Para Perlin; Lopes (2015) ela permite que computadores e sistemas abstraíam e derivem informações de maneira significativas de imagens digitais e vídeos.

Todo o processo da Visão computacional abrange aquisição de imagens, seleção, análise, identificação e extração de informações. Os estudos de visão computacional convertem o conteúdo visual digital em descrições perceptíveis para reunir dados multidimensionais. Esses dados são então transformados em linguagem legível (lógica-matemática) por computador para auxiliar no processo de tomada de decisão (RUSSEL et al., 2008).

Geralmente os sistemas abrangem o reconhecimento de objetos em imagens e a transformação destes em informações que são processadas e posteriormente manipuladas por algum software especial. Rehem e Trindade (2010) apresentam as funcionalidades mais comuns na maioria dos sistemas de visão computacional, a saber:

Aquisição de imagem – Processo de aquisição de uma imagem ou o conjunto delas a partir de sensores de câmeras. As imagens podem ser bidimensionais, tridimensionais ou ainda uma sequência de imagens.

Pré-processamento – Realizado antes de obter as informações de uma imagem, de forma a aplicar métodos específicos que facilitem a identificação de um objeto, como por exemplo, destaque de contornos, bordas e/ou figuras geométricas.

Deteção e segmentação – Processo realizado para destacar regiões relevantes da imagem, segmentando-as para processamento posterior.

Extração de características – Extração de características matemáticas que compõem a imagem.

Processamento em alto nível – Processo de validação dos dados obtidos, estimativa de parâmetros sobre a imagem e ainda classificar os objetos em evidência em diferentes categorias.

Ainda segundo Rehem e Trindade (2010) o ser humano consegue observar e interpretar objetos de forma muito rápida. Isso acontece devido a uma parte do cérebro chamada córtex visual, considerada uma das partes mais complexas do sistema de processamento do cérebro. O que leva muitos cientistas a concentrarem suas pesquisas em entender esta parte do cérebro e levar essas ideias para o campo da visão computacional, com o intuito de que máquinas e robôs sejam capazes de auxiliar o homem em suas atividades diárias (Tabela 9).

Tabela 9 - Estudos em Visão Computacional

Estudo	Referências
Aplicações ligadas ao meio ambiente – é possível detectar mudanças ambientais em tempo real, analisando imagens de satélites, tomando medidas de forma automática. Além de análises de eventos específicos como migração ou confinamento de aves em situações de estresse térmico.	RODRIGUES (2006)
Na indústria - na área de controle de qualidade desde a fabricação de produtos, como na caracterização e classificação.	FRICK (2008);
Detecção de obstáculos para carros autônomos utilizando aprendizado profundo.	TRINDADE et al. (2018)
Análise de Performance de um Algoritmo de Reconhecimento Facial por Visão Computacional.	BÖHM (2021)
Detecção de animais bovinos utilizando imagens aéreas por meio de redes neurais.	TAKANO; ALMEIDA; DA SILVA (2021)

O processo de aprendizagem de uma máquina ocorre dentro do campo da visão computacional com o treinamento e validação de redes neurais convolucionais (CNNs) que tem seu início com o processo de segmentação manual, este conhecido como *Ground Truth*. A segmentação semântica preve saídas de imagens densas, com aplicação de máscara especificada por suas classes, a partir de imagens de entradas.

Para treinar uma rede convolucional se faz necessário um grande conjunto de dados com *Ground Truth*, ou seja, imagens com segmentação de primeiro plano, com anotações verdadeiras. No entanto, tal conjunto de dados é difícil de construir porque exige que as anotações sejam realizadas de forma manual. Principalmente quando se diz respeito a cenas urbanas o trabalho é mais complexo, Cordets et al. (2016) afirmam que nenhuma corrente de conjunto de dados captura adequadamente a complexidade de cenas urbanas do mundo real.

Entretanto existem pesquisas voltadas a melhorar esse processo, que é o caso do conjunto de dados Cityscapes, que é composto por um grande e diversificado conjunto de sequências de vídeo estéreo gravados em ruas de 50 cidades diferentes, principalmente na Alemanha, 5000 imagens densas têm nível de pixel de alta qualidade nas anotações, 20.000

imagens adicionais têm anotações grosseiras para permitir métodos que aproveitam grandes volumes de dados fracamente rotulados (Figuras 7 e 8).

Essas anotações tem como principal diferença a forma de interpretação das classes pelas redes, principalmente no que tange às sombras das classes abordadas, que pode facilmente confundir uma rede no estudo da visão computacional. Sendo que nos *ground truth* com anotações grosseiras ela é vista como sua origem ou em certos casos descartada.



FONTE: Cordets et al. (2016)

Figura 7 - *Ground truth* de imagem RGB do *Dataset Cityscapes* - Anotações finas



FONTE: Cordets et al. (2016)

Figura 8 - *Ground truth* de imagem RGB do *Dataset Cityscapes* - Anotações grosseiras

Além do *Cityscapes*, pode-se citar o *DeepScene* que tem seu conjunto de dados gerados a partir de imagens da floresta de Freiburg – Alemanha, com 6 classes de anotações verdadeiras (obstáculo, trilha, céu, grama, vegetação e vazio).

Russel et al. (2008) a fim de melhorar esse desenvolvimento de grandes bancos de dados de imagens segmentadas com anotações verdadeiras, elaboraram uma ferramenta de anotações aberta na *Web*, a *LabelMe*, que permite fácil anotação de imagens e compartilhamento instantâneo de tais anotações pelos usuários inscritos. Um resumo do

conteúdo do banco de dados *LabelMe* em 21 de dezembro de 2006 apresentava 111490 polígonos, com 44059 polígonos anotados usando a ferramenta online e 67431 polígonos anotados offline. Há 11845 imagens estáticas e 18524 quadros de sequência com pelo menos um objeto rotulado.

A visão computacional desempenha um papel fundamental para a eficácia das pesquisas voltadas para inteligência artificial. A segmentação de imagens tem se mostrado muito importante para avanços em pesquisas de aprendizagem profunda, permitindo localizar objetos e elementos importantes em imagens *RGBs*.

Ainda de acordo com Russel et al (2008) a utilização de imagens segmentadas de ambientes com *Ground Truth* para treinamentos de redes neurais pode ser gerada manualmente com a utilização de *softwares* de edição de imagens.

3. MATERIAIS E MÉTODOS

3.1. Localização e características da área de estudo

A parte experimental desta pesquisa foi realizada na Universidade Federal da Grande Dourados – Unidade II, localizada nas coordenadas geográficas 22° 11' S, 54° 56' W', uma altitude de 464 m (Figura 9), com classificação climática segundo Köppen-Geiger tipo Am (clima de monções) com invernos secos e verões quentes, onde a temperatura do mês mais quente (janeiro) é superior a 22°C e dos meses mais frio (junho e julho) é inferior a 18°C. Além disso, a precipitação média anual é de 1500 mm ano⁻¹ e temperatura média 22 °C ano⁻¹ (Alvares et al., 2013).





Figura 9 - Localização geográfica e experimental

A Universidade Federal da Grande Dourados – Unidade II foi a área para parte prática da pesquisa, devido a sua localização distante do centro urbano de Dourados (MS) e estar passando por processo exponencial de antropização nos últimos 16 (dezesesseis) anos, como pode ser observado nas Figuras 10 e 11.



FONTE: Google Earth Pro - Mapas (2020)

Figura 10 - Área da Unidade II - UFGD no ano de 2004



FONTE: Google Earth Pro - Mapas (2020)

Figura 11 - Área da Unidade II - UFGD no ano de 2020

O campus localiza-se no km 12 da Rodovia Dourados/Itahum, tem uma área de aproximadamente 31 hectares e apresenta um ambiente heterogêneo, com diferentes tipos de uso e ocupação do solo.

A Unidade II, também chamada de “Cidade Universitária” tem instalada em sua área 10 das 12 unidades acadêmicas, diversos núcleos e laboratórios de pesquisa, além dos principais espaços de socialização, estudo e assistência – tais como biblioteca, restaurante universitário e centro de convivência. Sendo assim, este espaço é o ambiente de convivência da maior parte da comunidade universitária (RUSSO, 2019).

Devido a este grande desenvolvimento, houve inúmeras mudanças na paisagem desta área, principalmente o número de construções realizadas, bem como mudanças na cobertura da superfície com a troca do solo nu por pavimentos impermeáveis.

3.2. Metodologia

O desenvolvimento desta pesquisa obedeceu a três etapas de execução:

Na primeira etapa foi realizado o **Experimento de Campo**, o qual foi possível construir um banco de dados através das coletas dos elementos climáticos temperatura e umidade do ar. Posteriormente foi realizado cálculo do índice de temperatura e umidade (ITU) em função dos dados obtidos e avaliação das informações, a fim de classificar os pontos estudados.

A segunda etapa consistiu na realização da **Segmentação Semântica** das imagens reais dos pontos coletados para posterior extração de características matemáticas, a fim de utilização dos dados obtidos na construção da rede neural.

Por fim, a terceira etapa que foi a construção de um modelo lógico-matemático para avaliação da área estudada, através de algoritmo de programação com utilização de uma **Rede Neural Artificial Profunda**.

3.2.1. Experimento de Campo

Neste experimento foram considerados 9 pontos de interesse na área da Unidade II da UFGD (Figura 9), quais sejam:

- ponto 1A: área com arborização e piso asfáltico;
- ponto 2A: área sem sombreamento e piso de concreto;
- ponto 3A: área com arborização e piso gramado;
- ponto 1B: área entre duas edificações e piso em concreto;
- ponto 2B: área com arborização e piso em bloco de concreto;
- ponto 3B: área sem sombreamento e piso gramado;
- ponto 1C: área entre duas edificações e piso gramado;
- ponto 2C: área sem sombreamento e piso de terra (solo nu);
- ponto 3C: área sem sombreamento e piso asfáltico.

A título de comparação, foram utilizados os dados oficiais da estação meteorológica localizada na Embrapa Agropecuária Oeste, cujas coordenadas são 22° 16' latitude sul; 54° 49" longitude oeste e altitude média de 452 m.

Os dados coletados no experimento foram 40 dias de verão (calor) e 40 dias de inverno (frio). A fim de considerar somente as características climáticas semelhantes, as coletas ocorreram de 01/12/2020 a 01/03/2021 para verão (calor) e de 01/06/2021 a 10/08/2021 para o inverno (frio).

Para a coleta dos elementos climáticos de interesse, quais sejam Temperatura (T) e Umidade relativa (UR), foi utilizado um sistema de aquisição de dados *datalogger weireless* completamente automatizado e calibrado pelo INMETRO. O equipamento é composto por um sensor de temperatura e umidade (*wi fi*), um transmissor de sinal (*airgate*) e um sistema de processamento e armazenamento de dados (*fieldlogger*), programado para mensurar as informações a cada 5 minutos e armazenar as médias horárias das 06h00m às 18h00m, horário local. Consequentemente o INMET já disponibilizara as médias horárias oficiais de T e UR que ela registrava ao final de cada dia experimental.

De forma a representar a realidade do microambiente climático e das classes de coberturas das superfícies de interesse os suportes com sensores foram posicionados a 1,1m de altura da superfície.

Após a mensuração dos dados de T e UR foi realizada a tabulação dos dados em planilhas eletrônicas, em seguida foi calculado o ITU utilizando a Equação 1. De posse desses valores foi possível classificar os ambientes segundo as faixas relativas às condições de exposição a situações de conforto térmico ambiental estabelecidos por Wang et al. (2022) na Tabela 6.

3.2.1.1. Análise dos dados

Os dados obtidos foram submetidos a análise estatística para verificação das diferenças existentes nos microambientes em estudo. As médias de ITU foram submetidas à análise de variância e regressão com o *software R*® (2020) para comparação dos diferentes microambientes e estações, verificando os níveis de possível desconforto decorrentes nos pontos, considerando as diferentes características das superfícies.

O experimento foi montado em parcelas subdivididas, tendo nas parcelas um esquema fatorial 10 x 2 (10 microambientes e 2 estações do ano), e nas subparcelas os horários de

observações (13 horários), no Delineamento em Blocos Casualizados (D.B.C.), com 40 repetições (dias experimentais).

Para o desdobramento estatístico das diferenças significativas foi utilizado teste Scott Knott, a 5% de probabilidade.

3.2.3. Segmentação Semântica

A máscara densa projetada nas imagens destaca os aspectos considerados relevantes para o estudo do microclima, e essa conversão de informações em características matemáticas foram utilizadas como fatores na camada de entrada da rede neural artificial.

A máscara de segmentação das imagens foi realizada de forma manual com a utilização do *Software Adobe Photoshop CC 2019*. A escolha do *software* se deu pela precisão na manipulação do mesmo. As imagens foram segmentadas considerando as características das imagens com anotações grosseiras, levando em consideração a capacidade de interpretação das classes pelas redes e o objeto de estudo da pesquisa, ou seja, considerando as sombras como os elementos de sua origem.

As classes de cores utilizadas para classificação das máscaras de segmentação manual foram baseadas nas classes utilizadas pelo banco de dados do *Cityscapes*, que aborda 21 (vinte e uma) categorias diferentes de elementos considerando cenas de áreas urbanizadas, porém com algumas particularidades considerando a paleta de cores do programa utilizado e o número menor de cores para esta finalidade, como pode ser observado na Tabela 10.

Tabela 10 - Classes de cores utilizadas na segmentação das imagens

Faixa	Classe	Cores
0	vazio/neutro	
1	solo	
2	grama	
3	asfalto	
4	concreto	
5	construção	
6	vegetação	
7	céu	
8	placas/sinal de trânsito	
9	peessoa	
10	carro/motocicleta/ônibus	

O próximo passo se deu com a obtenção das características matemáticas das imagens segmentadas. Foi realizado a extração das porcentagens das cores referentes em cada classe. Essas porcentagens foram calculadas por um *script open source* do grupo PHP (Personal Home Page, 2021) (Anexo 1), editada e executada com auxílio do *software* Visual Studio Code (2021), e a resposta retornada em *HyperText Markup Language* (HTML).

3.2.4. Rede Neural Artificial Profunda

Neste trabalho foi construído um algoritmo de programação utilizando redes neurais multicamadas (MLP) com auxílio do *Software Python*[®] (2020), a rede proposta possui 1 (uma) camada de entrada, 1 (uma) camada intermediária e 1 (uma) de saída. Com base nesses dados o modelo da arquitetura selecionada para a rede foi a *Feed Forward* (FF) com o aprendizado de máquina sendo do tipo supervisionado, o qual consistiu na alimentação e treinamento do sistema em 2 (duas) etapas – O *Feedforward* e o *FeedBackward* (Figura 12).




Figura 12 - Diagrama esquemático da arquitetura da rede

No cenário criado, foram estabelecidos 12 (doze) neurônios na camada de entrada, quais sejam, os ITU's, os locais, as horas e as estações, e mais as informações extraídas da segmentação, ou seja, as porcentagens das composições das cenas, somando mais 8 (oito) neurônios, os quais são, presença de solo, presença de grama, presença de concreto, presença de asfalto, presença de árvore, presença de edificações, presença de céu e a presença de outros. E para a camada de saída foram considerados 5 (cinco) neurônios, cada neurônio representando uma das 5 classes de conforto do IBEH.

Notoriedade para o que foi considerado como presença de outros (p_{outros}), ou seja, tudo que não faz parte das categorias de classes relevantes no estudo, foram classificados como outros, por exemplo carros, ônibus, bancos, pedestais, lixeiras, placas, etc.

A arquitetura ideal de uma rede usa tantos neurônios quanto forem necessários para resolver o problema, mas nunca mais do que esse número para não atrapalhar o processo de treinamento. Portanto, através de ajustes empíricos experimental o número de neurônios na camada intermediária da rede fixou-se em 18. Os demais parâmetros utilizados podem ser observados na Tabela 11.

Tabela 11 - Parâmetros projetados na rede

Elementos da rede
Neurônios na camada de entrada = 12 (ITU, local, hora, estação, p_árvores, p_grama, p_asfalto, p_concreto, p_solo, p_céu, p_outros, p_edifícios)
Números de camadas ocultas = 1
Neurônios na camada oculta = 18
Neurônios na camada de saída = 5 (IBEH – 0 “muito ruim”, 1 “ruim”, 2 “médio”, 3 “bom”, 4 “muito bom”)
Dados de treinamento = 80%
Dados de teste = 20%
Número de épocas = 2000
Mini-lotes = 10
Taxa de aprendizagem = $1e-4$

A abordagem utilizada no modelo para a saída da rede foi o vetor de probabilidade, aonde a rede retorna as classes com o grau de pertencimento de cada uma, ou seja, como a probabilidade de ela pertencer a uma determinada classe esperada de forma probabilística. Ao invés de a rede ser direta na resposta e acender somente o neurônio que ela acredita ser a classificação correta, ela retorna a saída de forma indireta com o grau de pertencimento de cada classe.

A relação das classes de IBEH utilizadas na camada de saída da rede foram correlacionadas conforme as zonas de conforto apresentadas por Wang et al. (2022), bem como para que as classes pudessem ser repassadas à rede como função numérica, foi realizado uma conversão através da função SE no *software* Excel (Tabela 12).

Tabela 12 - Escala da classificação de conforto e conversão das classes da camada de saída

Faixas	Intervalo do ITU	Características	Classes de IBEH	Classe Numérica
1	< 5,9	Resfriamento muito elevado	Muito ruim	0
2	6,0 a 8,9	Resfriamento elevado	Muito ruim	0
3	9,0 a 11,9	Frio	Ruim	1
4	12,0 a 14,9	Desconforto ao frio	Ruim	1
5	15,0 a 17,9	Leve desconforto ao frio	Médio	2
6	18,0 a 20,9	Limite inferior da zona de conforto	Bom	3
7	21,0 a 23,9	Centro da zona de conforto	Muito bom	4
8	24,0 a 26,9	Limite superior da zona de conforto	Bom	3
9	27,0 a 29,9	Leve desconforto ao calor	Médio	2
10	30,0 a 32,9	Desconforto ao calor	Ruim	1
11	> 33	Aquecimento elevado	Muito ruim	0

Fonte: Wang et al. (2022) adaptado

Para ativação dos neurônios da rede foi utilizado a função ReLU em todas as camadas. Sua principal vantagem em relação às outras é que ela não ativa todos os neurônios ao mesmo tempo. Para a função ReLU se a entrada for negativa, ela será convertida em zero e o neurônio não será ativado. Isso significa que, ao mesmo tempo, apenas alguns neurônios são ativados, tornando a rede esparsa e eficiente e fácil para a computação (DATA SCIENCE ACADEMY, 2021).

Após a elaboração do algoritmo da rede proposta, ela foi testada em um banco de dados aleatório, *open source*, com o intuito de verificar se a rede converge e se a estrutura e configuração da rede é consistente e razoável. O procedimento seguinte foi o treinamento da rede com 80% dos dados e na sequência o teste com os outros 20%. O script do algoritmo utilizado pode ser observado no Anexo 2.

Todavia, esses ajustes empíricos mostraram que o IBEH, na camada de saída da rede, está diretamente relacionado com o ITU, que é um dos neurônios inseridos na camada de entrada. Levando, desta forma, a pesquisa a uma segunda proposta de algoritmo sem o ITU.

Neste segundo momento da elaboração do algoritmo foram realizadas algumas alterações em seus parâmetros visando uma melhoria em sua acurácia mesmo estas mudanças dificultando o seu treinamento. Essas podem ser observadas na Tabela 13.

Tabela 13 - Parâmetros corrigidos projetados na rede

Elementos da rede
Neurônios na camada de entrada = 11 (local, hora, estação, p_árvores, p_grama, p_asfalto, p_concreto, p_solo, p_céu, p_outros, p_edifícios)
Números de camadas ocultas = 1
Neurônios na camada oculta = 18
Neurônios na camada de saída = 5 (IBEH – 0 “muito ruim”, 1 “ruim”, 2 “médio”, 3 “bom”, 4 “muito bom”)
Dados de treinamento = 90%
Dados de teste = 10%
Número de épocas = 4000
Mini-lotes = 1
Taxa de aprendizagem = $1e-4 \times 2$

Foi retirado o ITU da camada de entrada da rede, pois ficou implícito a sua influência na resposta retornada pela rede no primeiro algoritmo criado. Os dados de treinamento e teste foram alterados para ajustar a metodologia de validação k-fold, os números de épocas e a taxa de aprendizagem também foram modificados pois a rede sofre muito mais para convergir quando o ITU é retirado da camada de entrada. O método Validação cruzada k-fold considerou $k=10$ com 23 dados em cada subconjunto. Esse método permitiu que todos os dados de treinamento em um determinado momento da pesquisa também fossem testados.

O script do algoritmo alterado pode ser observado no Anexo 3.

4. RESULTADOS E DISCUSSÕES

As classificações dos cenários para as duas estações com base na escala de conforto utilizada na Tabela 11, obtidas após tabulação e cálculo dos dados obtidos do experimento a partir das médias do ITU para cada ponto podem ser observadas nas Tabelas 14 e 15.

Tabela 14 - Classificação dos microambientes para a situação de verão

HORA	3C	2A	2C	3B	INMET	1B	1C	1A	2B	3A
6	24,2	24,0	23,8	22,6	23,0	23,0	22,6	22,4	22,2	22,0
7	25,7	25,0	25,0	23,9	24,1	24,2	23,9	23,4	23,2	22,6
8	28,0	27,5	26,8	25,6	25,7	25,2	24,8	24,4	23,9	23,3
9	30,2	29,5	28,2	27,1	26,7	26,0	25,6	25,1	24,5	24,0
10	31,9	30,9	29,4	28,2	27,5	26,7	26,2	25,6	25,1	24,6
11	33,1	31,8	30,3	28,9	28,2	27,3	26,7	26,0	25,4	24,9
12	34,2	32,7	31,1	29,4	28,7	27,7	27,1	26,2	25,7	25,4
13	35,0	33,1	31,8	29,7	29,0	28,1	27,5	26,5	26,0	25,7
14	35,6	33,6	32,2	30,0	29,2	28,3	27,7	26,6	26,1	25,8
15	36,0	33,9	32,5	30,1	29,4	28,4	27,8	26,7	26,2	25,8
16	35,8	33,6	32,4	29,6	29,0	28,1	27,5	26,7	26,2	25,5
17	34,3	32,0	30,8	28,4	28,1	27,5	26,9	26,4	25,9	25,0
18	28,8	28,0	27,1	25,0	24,8	26,6	25,2	25,2	25,0	24,1

Tabela 15 - Classificação dos microambientes para a situação de inverno

HORA	3C	2A	2C	3B	INMET	1B	1C	1A	2B	3A
6	13,0	12,6	11,5	10,2	9,9	9,3	9,0	6,9	6,4	6,4
7	15,5	14,8	13,5	12,1	11,7	10,8	10,4	9,6	8,9	9,0
8	18,9	17,7	16,4	14,8	14,2	13,0	12,6	11,9	11,2	11,1
9	22,8	20,6	19,2	17,2	16,7	15,3	14,8	14,1	13,5	13,3
10	25,6	23,6	22,2	19,4	18,9	17,6	17,0	16,0	15,4	15,1
11	27,3	25,7	24,5	21,1	20,6	19,4	18,8	17,6	17,0	16,6
12	28,4	27,0	25,7	22,4	21,9	20,6	20,0	18,9	18,3	17,8
13	29,2	27,9	26,3	23,4	22,8	21,5	20,9	19,8	19,2	18,6
14	29,6	28,2	26,7	23,8	23,2	21,8	21,1	20,2	19,5	19,1
15	29,6	28,1	26,7	23,7	23,2	21,8	21,1	20,2	19,6	19,2
16	28,7	26,8	25,6	22,4	21,9	20,7	20,3	19,6	19,1	18,9
17	25,5	24,3	22,9	19,9	19,6	18,8	18,0	17,1	16,5	16,3
18	18,0	18,4	17,8	17,3	16,9	15,7	14,6	13,0	12,6	11,9

Nas Figuras 13 e 14 é possível refinar essas observações através dos gráficos gerados com a escala de conforto e limites superior e inferior de conforto em evidências.




Figura 13 - ITU's médios dos ambientes em função das horas – Verão

Analisando a Figura 13 os ambientes 3C (área sem sombreamento e piso asfáltico) e 2A (área sem sombreamento e piso de concreto) são os mais desconfortáveis. Estes resultados são justificados por pesquisa de Sen; Roesler (2019), ao concluírem que o asfalto e concreto representam materiais com elevados valores de absorvidade e emissividade, contribuindo para o aquecimento do ar e formação de ilhas de calor, principalmente em microescala, devendo ser evitados sempre que possível no processo de ocupação rural.

Os ambientes mais confortáveis na estação verão são os com maiores densidades de árvores em seu entorno, 1A (área com arborização e piso asfáltico), 2B (área com arborização e piso em bloco de concreto) e 3A (área com arborização e piso gramado). Ribeiro (2021) estudou a análise da influência da vegetação arbórea no comportamento térmico dos diferentes tipos de revestimento do solo. Seus resultados apontaram que os revestimentos instalados sob as copas das árvores obtiveram os melhores desempenhos térmicos.




Figura 14 - ITU's médios dos ambientes em função das horas - Inverno

Na Figura 15 observa-se que devido ao frio todos os ambientes se mostraram desconfortáveis nas primeiras horas da manhã, principalmente os que tem maiores densidades de árvores.

Os microambientes mais quentes no período do verão (3C e 2A) se mostraram também fora do limite superior de conforto na estação do frio, principalmente no período da tarde, pois, segundo Pan et al. (2022), possuem baixa inércia térmica e oscilam muito de temperatura entre o resfriamento noturno e o aquecimento causado pela exposição ao calor diurno. Corroborando com a pesquisa realizada por Freitas; Azerêdo (2020) que mostraram que asfalto e concreto, os mesmos materiais de 3C e 2A, possuem altos valores de absorvidade (α) e emissividade (ϵ), $\alpha = 0,90$; $\epsilon = 0,90$ do asfalto e $\alpha = 0,60$; $\epsilon = 0,88$ do concreto, contribuindo decisivamente para o aquecimento do ar, principalmente em microescala.

4.1. Estatística experimental

A análise de variância e regressão dos microambientes foi executada a fim de constatar os locais que exercem maior influência nos níveis de desconforto térmico para os usuários locais através do ITU, bem como a diferença significativa entre eles.

Houve diferença significativa para as médias do ITU entre as estações estudadas, o que já era esperado devido às diferenças de valores encontradas (Tabela 16). Esse resultado induziu a avaliação dessas diferenças pela aplicação do Teste de média (Tabela 17).

Tabela 16 - Resumo da análise de variância para a avaliação das estações verão e inverno

Fonte de Variação	GL	SQ	QM	F	p-valor
Estação	1	128756.00	128756.00	4982.00**	2.00E-16
Resíduo	10398	268706.00	26.00		
Total	10399	397462.00			

GL= Graus de liberdade, SQ= Soma de quadrados, QM= Quadrado médio, F= Teste F

** Significativo a nível de 1%

Tabela 17 - Médias de ITU para as estações verão e inverno

Estação	Médias
Verão	25.64 a
Inverno	18.60 b

Médias seguidas de letras minúsculas diferem entre si pelo teste Scott Knott ($p \leq 0.05$)

Análise de variância também foram realizadas para avaliar as diferenças significativas do ITU entre os ambientes estudados para as diferentes estações. O resumo das análises entre os microambientes para a estação Verão, bem como a análise para a estação Inverno. É possível observar que $F > F_{\text{crítico}}$ que por sua vez é menor que 1%, significando que houve diferenças significativas entre os microambientes, em ambas as estações ser observados nas Tabelas 18 e 19.

Tabela 18 - Resumo da análise de variância para a avaliação dos microambientes - Verão

Fonte de Variação	GL	SQ	QM	F	p-Valor
Microambientes	9	25806.00	2867.35	256.82**	2.20E-16
Resíduo	5190	57945.00	11.16		
Total	5199	83751.00			

GL= Graus de liberdade, SQ= Soma de quadrados, QM= Quadrado médio, F= Teste F

** Significativo a nível de 1%

Tabela 19 - Resumo da análise de variância para a avaliação dos microambientes - Inverno

Fonte de Variação	GL	SQ	QM	F	p-Valor
Microambientes	9	48968.00	5440.90	207.65**	2.20E-16
Resíduo	5190	135987.00	26.20		
Total	5199	184955.00			

GL= Graus de liberdade, SQ= Soma de quadrados, QM= Quadrado médio, F= Teste F

** Significativo a nível de 1%

Procedeu-se desta forma para o desdobramento da análise a fim de obter a diferença mínima significativa entre os ambientes, as quais são apresentadas pelas letras minúsculas nas Tabelas 20 e 21 para verão e inverno, respectivamente.

Tabela 20 - Médias de ITU para o verão

Microambientes	ITU
3C	29.99 a
2A	28.04 b
INMET	26.94 c
3B	26.89 c
1B	25.65 d
1C	25.14 e
2C	24.62 f
1A	23.37 g
2B	22.90 h
3A	22.87 h

Médias seguidas de letras minúsculas diferem entre si pelo teste de Scott Knott ($p \leq 0.05$)

O desdobramento realizado para estação de verão (Tabela 20) evidencia a importância do sombreamento, principalmente arbóreo, para os microambientes estudados mesmo estes tendo a presença de superfícies artificiais. Ribeiro et al. (2021) analisou a influência da vegetação arbórea no comportamento térmico de revestimentos no solo. Seus resultados apontaram que pisos impermeabilizados sob as copas das árvores obtiveram melhores desempenhos térmicos se comparados com quaisquer outros expostos ao Sol.

Tabela 21 - Médias de ITU para o inverno

Microambientes	ITU
3C	24.04 a
2A	22.78 b
2C	21.49 c
3B	19.09 d
INMET	18.60 d
1B	17.44 e
1C	16.83 e
1A	15.79 f
2B	15.20 g
3A	14.77 g

Médias seguidas de letras minúsculas diferem entre si pelo teste Scott Knott ($p \leq 0.05$)

Na Tabela 21, ao se analisar a estação de inverno, fica evidenciado que os ambientes mais confortáveis do verão são os mais desconfortáveis no inverno, no início e final do dia, o que se justifica pela presença de arborização, que dificulta a incidência da radiação solar, responsável pelo aquecimento local. Segundo Souza et al. (2021), os tipos de uso e cobertura do solo influenciam diretamente na intensidade de calor local, e este varia diretamente com as horas do dia.

Como forma de auxiliar na construção de uma superfície de resposta do ITU em função dos horários para as estações abordadas, foram ajustadas equações de regressão e os seus coeficientes de determinação (R^2) obtidos a partir da análise (Tabelas 22 e 23). Assim sendo, o modelo que melhor representa o perfil dos microambientes é a função polinomial de 4º grau.

Tabela 22 - Equações ajustadas para o ITU no verão

Microambientes	Equações	R ²
1A	$y = -0.0021x^4 + 0.0876x^3 - 1.333x^2 + 9.6845x - 6.3639$	0.9838
1B	$y = -0.0018x^4 + 0.0773x^3 - 1.3079x^2 + 10.564x - 8.6822$	0.9761
1C	$y = -0.0015x^4 + 0.0733x^3 - 1.4154x^2 + 12.554x - 16.537$	0.9784
2A	$y = -0.0044x^4 + 0.2065x^3 - 3.5642x^2 + 27.546x - 53.201$	0.9684
2B	$y = -0.0021x^4 + 0.0848x^3 - 1.2928x^2 + 9.4094x - 5.9832$	0.9837
2C	$y = -0.0025x^4 + 0.1203x^3 - 2.2068x^2 + 18.42x - 33.287$	0.9690
3A	$y = -0.003x^4 + 0.1329x^3 - 2.1878x^2 + 16.429x - 25.693$	0.9815
3B	$y = -0.0028x^4 + 0.1332x^3 - 2.4136x^2 + 19.743x - 34.253$	0.9549
3C	$y = -0.005x^4 + 0.2187x^3 - 3.5953x^2 + 27.149x - 51.386$	0.9880
INMET	$y = -0.0009x^4 + 0.0471x^3 - 0.9275x^2 + 8.7573x - 5.2424$	0.9869

Tabela 23 - Equações ajustadas para o ITU no inverno

Microambientes	Equações	R ²
1A	$y = -0.0025x^4 + 0.099x^3 - 1.5913x^2 + 13.697x - 36.248$	0.9990
1B	$y = 0.0006x^4 - 0.0488x^3 + 0.979x^2 - 5.3804x + 15.997$	0.9989
1C	$y = 0.0001x^4 - 0.0257x^3 + 0.5976x^2 - 2.7507x + 9.1833$	0.9979
2A	$y = -0.0011x^4 + 0.0275x^3 - 0.2894x^2 + 4.414x - 8.2031$	0.9946
2B	$y = -0.0021x^4 + 0.0822x^3 - 1.303x^2 + 11.595x - 31.41$	0.9982
2C	$y = -0.0004x^4 - 0.0041x^3 + 0.234x^2 + 0.6475x + 0.3467$	0.9949
3A	$y = -0.0033x^4 + 0.139x^3 - 2.2967x^2 + 18.76x - 49.408$	0.9980
3B	$y = 0.0003x^4 - 0.0322x^3 + 0.6363x^2 - 2.2185x + 7.0563$	0.9986
3C	$y = -0.0036x^4 + 0.1464x^3 - 2.379x^2 + 20.347x - 51.029$	0.9870
INMET	$y = 0.0005x^4 - 0.0419x^3 + 0.8093x^2 - 3.6007x + 10.656$	0.9988

4.2. Segmentação Semântica dos microambientes

Os resultados das máscaras de segmentação manual, ou *Ground Truth*, das imagens originais dos ambientes, bem como as porcentagens das classes extraídas de cada cena podem ser observadas na Tabela 24.

Tabela 24 - Segmentação semântica das imagens e as porcentagens das classes

Ponto	RGB	Ground Truth	Porcentagem das classes
1A			árvores = 71,24% piso asfáltico = 18,31% edifícios = 5,44% piso de concreto = 0,70% céu = 3,24% grama = 0,70% outros = 0,37%
1B			edifícios = 80,75% piso de concreto = 12,71% céu = 3,88% árvores = 0,74% outros = 1,92%
1C			edifícios = 47,62% árvores = 25,31% grama = 14,95% céu = 7,31% solo nu = 1,38% piso de concreto = 0,84% outros = 2,59%

2A



piso de concreto = 28,72%	árvores = 19,42%
edifícios = 24,20%	grama = 4,15%
céu = 22,61%	outros = 0,51%

2B



árvores = 86,67%	céu = 1,34%
piso de concreto = 4,30%	outros = 2,49%
edifícios = 5,20%	

2C



grama = 36,22%	árvores = 9,28%
edifícios = 25,96%	piso de concreto = 1,15%
solo nu = 13,33%	outros = 1,00%
céu = 13,06%	

3A



árvores = 90,02%	piso de concreto = 0,68%
grama = 3,63%	céu = 0,26%
edifício = 4,14%	outros = 1,27%

3B



grama = 42,07%	árvores = 5,81%
céu = 40,18%	piso asfáltico = 0,97%
edifícios = 9,47%	outros = 1,23%

3C



■ piso asfáltico = 47,62%

■ céu = 24,57%

■ árvores = 15,15%

■ edifícios = 4,76%

■ grama = 4,09%

■ piso de concreto = 3,75%

□ outros = 0,06 %

De posse das porcentagens de cada classe retornadas pelo *script* foi possível utilizar os dados como neurônios na camada de entrada da rede, possibilitando o enriquecendo de seu treinamento.

4.3. Rede Neural Artificial Profunda

Esse primeiro experimento considera o ITU como um dos neurônios de entrada da rede. O principal objetivo aqui é verificar se a arquitetura da rede faz sentido e se de fato ela consegue classificar uma boa porcentagem dos dados da entrada. Um dos maiores desafios no projeto foi encontrar uma configuração que conseguisse aprender a partir de um banco de dados com tamanho de 234. Contudo, não foi encontrado na literatura um banco de imagens sobre construções, coberturas de superfícies e suas indicações de conforto, o que reitera a importância de banco de dados construído.

No final do processo de treinamento é possível observar que houve uma evolução direta da acurácia, com origem em 10% (0.1) a 39% (0.39) no ponto inicial, que continuou a crescer de forma constante até o valor superior a 90% (0.9) nas últimas épocas. Oposto à acurácia, o erro começou próximo 0.2 e tendeu a 0.01 (Figura 15).




Figura 15 - Erro e acurácia da rede na fase de treinamento

Han; Kang (2022) estudaram dinâmicas para treinamento de rede neural e afirmaram que a diversificação de camadas torna a rede neural mais robusta a imprecisões, sendo ideal treinamentos com erros que tendam a 0 e acurácia que apresentem crescimento constante.

Este resultado reflete a importância da modelagem ao considerar que a rede neural foi proposta para o problema específico de classificar cenas de ambientes compostos por recursos naturais e edificações que refletem nas classes de conforto, o quê segundo Kholwal; Maurya (2021) são variáveis incertas e difíceis de qualificar. Além disso, tal resultado reforça que a

seleção dos parâmetros e funções da rede foram corretamente ajustados no processo anterior de ajuste empírico.

Frente ao desempenho obtido pela rede em seu treinamento, já era esperado que seu teste acompanharia este desenvolvimento. A acurácia oscilou bastante entre os lotes testados, mas ficou com uma média de 80% no teste, acertando 40 de 50 classes confrontadas, o que significa que a rede acerta bem mais do que a maioria dos casos, considerando que a chance de acerto é 20% (1/5) quando a rede escolhe aleatoriamente uma classe (Figura 16).




Figura 16 - Erro e acurácia da rede na fase de teste

Para se ter uma ideia da eficiência da rede foi realizado um teste com ela sem o treinamento. Neste caso é perceptível que o erro inicial que é de 2.0 é quase 10 vezes maior do que a rede já treinada, indicando que a rede estava longe da classificação ideal. Claramente a acurácia da rede sem treinamento se aproxima do classificador aleatório, aquele que escolhe uma classe aleatoriamente e tem uma chance de acerto de 20% (Figura 17).



Figura 17 - Erro e acurácia da rede - pré-treinamento

Quando se compara uma acurácia de 80% com uma de 20%, nota-se que o processo de aprendizagem foi eficaz. O que mostra que a escolha da arquitetura foi correta. Bem como os ajustes empíricos e a otimização razoável dos parâmetros utilizados.

4.3.1. Validando a rede neural - Resultados sem o ITU

Todavia, esses ajustes empíricos mostraram que o IBEH, na camada de saída da rede, está diretamente relacionado com o ITU, que é um dos neurônios inseridos na camada de entrada. Levando, desta forma, a uma segunda proposta de algoritmo sem o ITU, fato que alterou a camada de entrada da rede para 11 (onze) neurônios e confirmou a hipótese, tendo em vista que a acurácia alcançada no teste foi somente de 50%.

Com o intuito de melhorar esse resultado os parâmetros utilizados na segunda proposta foram sendo ajustados de forma empírica, conforme a Tabela 13, assim como na primeira arquitetura projetada. O que resultou em uma acurácia média de 62% (Figura 18).




Figura 18 - Acurácia da Rede - Teste

Um resultado superior ao anterior, mas bem abaixo da primeira proposta quando o ITU fazia parte da camada de entrada da rede. Entretanto estudos comparativos apontam que esse resultado ainda pode ser considerado promissor, dada a complexidade da proposta de classificação multiclasse.

Ienco et al. (2017) ao avaliarem a capacidade de redes neurais realizarem a classificação do solo utilizaram dois bancos de dados diferentes considerando a classificação baseada em objetos e baseada em pixels. Para o primeiro conjunto de dados onde eles utilizaram uma área de 42.000 ha com 70% da área com solo, através do processo de segmentação rotularam 11 classes diferentes de objetos. O segundo conjunto foi gerado a partir de uma série temporal anual de 23 imagens com resolução espacial onde obtiveram como referência final 37.900 pixels distribuídos em 9 classes. Os resultados obtidos pelos autores foram acurácias de 75,15 % e 83,98%, respectivamente.

Qiu et al. (2021) propuseram um modelo capaz de aprender representação conjunta de características ambientais, baseado em segmentação de imagens e rede neural. No final da pesquisa a estrutura proposta apresentou acurácias entre 76% e 81% e os autores concluíram que estes resultados são indicados para reproduzir mapas de cobertura do solo de áreas urbanizadas com qualidade consistente em larga escala, apoiar na tomada de decisões sobre ocupação de áreas e realizar análises de climatologia.

Considerando os resultados desta pesquisa com os de Ienco et al. (2017) e Qiu et al. é possível observar que experimentos envolvendo paisagens complexas para classificação multiclasse são mais difíceis de avaliar, devido aos diferentes tipos de cobertura da superfície, ocupação do espaço, céu, sombras, entre outros, porém se bem calibrados geram resultados mais amplos.

A média do erro de entropia cruzada na segunda proposta de algoritmo foi de 1.16 pontos, entretanto utilizar a metodologia de validação cruzada k-fold para melhorar o desempenho da rede permitiu avaliar as entropias a cada subconjunto testado, como pode ser visualizado na Figura 19.




Figura 19 - Validação cruzada do erro de entropia cruzada k-fold

No gráfico de validação é possível observar que a mediana tende a permanecer próximo de 0.55 pontos, independente do subconjunto. Dessa maneira, a média do valor de entropia tende a se situar na mesma região do eixo Y, o que denota certa estabilidade dos resultados independentemente da variação do k-fold.

Percebe-se que o número de dados discrepantes (*outliers*), é quase insignificante, levando em consideração o conjunto de dados em cada subconjunto. Igualmente, é perceptível

que a maioria dos resultados tende a se localizar numa entropia de 0 (zero) a 1 (um) ponto, de forma constante e independente do subconjunto.

Outro fator crítico da rede a ser analisado é a forma como ela acerta as classes de saída (IBEH) desejadas. Ao se testar ambientes de composição paisagística complexa, onde ocorrem extremos térmicos, explorando os valores do erro da saída de entropia cruzada do algoritmo, foi possível observar como a rede retorna à interação entre elementos de entrada e suas saídas (Tabela 25).

Tabela 25 - Classes retornadas pela Rede Neural na fase de teste

Local / Imagem RGB e Segmentada	Entradas		Saídas			Erro
	Características Local	Composição	Classe IBEH	Classe IBEH Esperada	Classe IBEH Retornada	
3B						
 	ITU = 10,2 Horas = 6h Estação = Inverno	Grama = 42,07% Céu = 40,18% Edifícios = 9,47% Árvores = 5,81% Piso asfáltico = 0,97% Piso de concreto = 0,0% Solo nu = 0,0% Outros = 1,23%	Muito Ruim = - 10.99 Ruim = 1.58 Médio = - 11.11 Bom = - 45.65 Muito Bom = -7.53	Ruim	Ruim	0.0001
2A						
	ITU = 33,6 Horas = 14h Estação = Verão	Piso de concreto = 28,72% Edifícios = 24,20% Céu = 22,61% Árvores = 19,42% Grama = 4,15% Piso asfáltico = 0,0% Solo nu = 0,0% Outros = 0,51%	Muito Ruim = 1.77 Ruim = 0.94 Médio = 1.15 Bom = - 0.95 Muito Bom = - 5.41	Muito Ruim	Muito Ruim	0.0013



1A



ITU = 20,9
Horas = 14h
Estação = Inverno

Árvores = 71,24%
Piso asfáltico = 18,31%
Edifícios = 5,44%
Céu = 3,24%
Piso de concreto = 0,70%
Grama = 0,70%
Solo nu = 0,0%
Outros = 0,37%

Muito Ruim = - 5.52
Ruim = 0.09
Médio = - 0.18
Bom = - 12.84
Muito Bom = - 4.74

Muito Bom

Ruim

0.8459



3A



ITU = 21,9
Horas = 6h
Estação = Verão


Árvores = 90,02%
Grama = 3,63%
Edifício = 4,14%
Piso de concreto = 0,68%
Céu = 0,26%
Piso asfáltico = 0,0%
Solo nu = 0,0%
Outros = 1,27%

Muito Ruim = - 4.94
Ruim = 0.29
Médio = - 0.12
Bom = -3.57
Muito Bom = -0.99

Muito Bom

Ruim

1.9557



2B



ITU = 20,9	Árvores = 86,67%	Muito Ruim = 5.43			
Horas = 18h	Piso asfáltico = 0,0%	Ruim = - 0.95			
Estação = Verão	Edifícios = 5,20%	Médio = - 0.91	Médio	Muito Ruim	9.9173
	Céu = 1,34%	Bom = - 5.37			
	Piso de concreto = 4,30%	Muito Bom = - 49.72			
	Gramma = 0,0%				
	Solo nu = 0,0%				
	Outros = 2,49%				

Ao analisar as cenas 3B e 2A na Tabela 25 é possível observar que estas foram as que retornaram menor erro entre as classes de saída esperada e observada na rede. Estes ambientes apresentam mais elementos em sua composição, como pode ser visto em sua imagem *Ground Truth*, se traduzindo teoricamente em ambientes mais complexos, porém com os elementos das cenas mais bem distribuídos, o que se traduziu em menores erros de entropia.

Ao se comparar os ambientes que incluem maior porcentagem de cobertura arbórea, nas cenas 1A, 3A e 2B, verifica-se o aumento do erro, de forma que as saídas esperadas e retornadas não são de mesma classe. Martins et al. (2021) utilizaram redes neurais profundas para avaliarem seu desempenho na identificação de diferentes espécies de árvores, comparando 1394 imagens aéreas de copas.

Com o estudo obtiveram 91% de acurácia, mas concluíram que ambientes arborizados resultam em elevados erros, entretanto deve-se considerar que as imagens utilizadas por eles são direcionadas para classificação binária envolvendo somente dois tons de cor.

Uma pesquisa com RNA foi desenvolvida e testada por Shah et al. (2022), para a estimativa do conforto térmico em espaços exteriores utilizando um estudo de caso com clima composto e modelos categorizados para as estações de verão e inverno. No final, eles concluíram que em muitos casos não é fácil reunir todas as variáveis para um determinado local.

Rhoden et al (2022) analisaram a mudança no uso da terra em uma Área de Proteção Ambiental (APA), e seu impacto na dinâmica econômica da região. Ao final concluíram que é necessário desenvolver ferramentas que estimulem a conservação de ecossistemas e exploração agropecuária sustentável.

Assim, a rede neural aqui proposta vem de encontro a descrição colocada por estes pesquisadores e os resultados de altos erros de entropia podem ser justificados pelo pequeno conjunto de dados usado no estudo, considerando um resultado de classificação multiclasse. Para Althnian et al., (2021) o tamanho do conjunto de dados é considerado uma propriedade crítica na determinação do desempenho de um aprendizado de rede neural.

5. CONCLUSÃO

Os modelos de algoritmos obtidos resultaram em acurácias nas fases de teste de 80% e 62%, para a rede com e sem ITU, respectivamente, resultados considerados satisfatórios, dada a complexidade das variáveis, tendo sido possível obter um modelo multiclasse para classificação de conforto ambiental. Podendo-se concluir que estas acurácias são boas e promissoras.

Os resultados obtidos por este estudo mostraram que as variáveis de entrada em um modelo de suporte à tomada de decisão baseado em rede neural artificial precisam ser aprofundadas para possibilitar a avaliação correta de impactos resultantes da antropização rural.

A utilização do erro de entropia cruzada nos algoritmos auxiliou em uma análise mais profunda da rede, sendo possível evidenciar as classificações dos microambientes considerados distintos pelas redes, além de ressaltar a diversificação com que a rede retorna as solicitações a ela impostas.

Modelagem que envolvam redes neurais para representação de ambientes arborizados precisam ser cuidadosamente construídos e testados visto que os tons de uma mesma cor refletem em elevado erro de entropia.

Ao se trabalhar com a elaboração de algoritmos de rede neural para classificação multiclasse são muitos os desafios que surgem. Para a presente pesquisa não foi praticável trabalhar com a codificação one-hot para apresentação dos valores dos erros em números naturais, pois a codificação com números inteiros gerou uma melhor convergência da rede neural.

Através das análises e classificações de conforto utilizadas, constatou-se a importância da arborização para o conforto térmico humano na estação verão, mesmo quando alteradas as coberturas das superfícies para pavimentos artificiais, do mesmo modo que esses ambientes se mostram desconfortáveis pelo frio na estação inverno. Verificou-se também que os ambientes mais desconfortáveis são os que tiveram suas superfícies alteradas para pavimentos artificiais sem sombreamento, obtendo impacto negativo independente da estação.

Ao se avaliar os diferentes tipos de ocupação é possível afirmar que a interferência mais sustentável para expansão do agronegócio ou urbanização no meio rural deve manter a arborização e evitar áreas abertas mesmo que gramadas devendo sempre que possível consorciar pisos asfálticos ou de concreto com sombreamento de árvores.

Os resultados obtidos por este estudo corroboram com as pesquisas em climatologia e ambiência ao constatar como a ação humana é capaz de produzir modificações no ambiente, capazes de alterar o microclima local.

O banco de dados elaborado para o estudo também pode ser considerado como um dos resultados da pesquisa, visto que ele pode ser disponibilizado em plataformas que contribuam em projetos privados e/ou de código aberto (*open source*) de qualquer lugar do mundo. Contribuindo com as pesquisas na área da IA - *Machine Learning*, *Deep Learning*, Visão Computacional, bem como Ambiência, Climatologia e Impactos Ambientais.

5.1 Sugestões para trabalhos futuros

- a. Aumentar o conjunto de dados (*dataset*).
- b. Mudança da abordagem: ao invés de usar segmentação de imagem manual e extração de características é possível usar a imagem em uma arquitetura de rede sem fazer esse pré-processamento.
- c. Trabalhar com uma arquitetura de rede diferenciada, ou seja, mais sofisticadas e podendo ainda aumentar o número de camadas ocultas.
- d. Trabalhar a codificação one-hot para apresentar os valores dos erros da rede em números naturais e normalizar os valores de saída da rede em porcentagens de pertencimento das classes.

6. REFERÊNCIAS BIBLIOGRÁFICAS

Adobe Photoshop CC 2019. Versão Adobe Photoshop: 20.0.0 20180920. r.24 20/09/2018: 1193433 x64.

ALMEIDA, M. L. ***Fugere Urbem no Século 21: Migração de Área Rural a Urbana como Ação Anti-capitalista e Colonial***. XV Congreso de la Asociación Latinoamericana de Investigadores de la Comunicación (ALAIIC). p.394-406, 2020.

ALVARES, C. A., STAPE, J. L., SENTELHAS, P. C., GONÇALVES, J. L. M. SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013.

ALVES, E. D. L.; VECCHIA, F. A. S. Influência de diferentes superfícies na temperatura e no fluxo de energia: um ensaio experimental. **Ambiência**, Guarapuava, v. 8, n. 1, p. 101 - 111, 2012.

ALTHNIAN, A., ALSAEED, D., AL-BAITY, H., SAMHA, A., DRIS, A.B., ALZAKARI, N., ABOU ELWAFA, A., KURDI, H. Impact of Dataset Size on Classification Performance: An Empirical Evaluation in the Medical Domain. **Applied Sciences**, v.11, n. 2, p. 796, 2021.

BARBOSA, X. C.; BEZERRA, R. F. Breve introdução à história da inteligência artificial. **Periódicos Jamaxi**, UFAC, ISSN 2594-5173, v. 4, n. 1, 2020.

BOCANEGRA, C. W. R. Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes. **Dissertação** (Mestrado em Transportes) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2002.

BÖHM, Samuel M. et al. **Análise de Performance de um Algoritmo de Reconhecimento Facial por Visão Computacional Aplicado a Sistemas Embarcados**. Monografia. Repósitório Institucional, Universidade de Federal de Santa Catarina, 2021.

BISHOP, C. M. Pattern recognition. **Machine learning**, v. 128, n. 9, 2006.

BRAGA, A. P.; FERREIRA, A. C. P. L.; LUDERMIR, T. B. Redes neurais artificiais: teoria e aplicações. **LTC Editora**, 2007.

BRAGA, C.C., SOARES, F.R., DANTAS, F.R.C., BARBIERI, L.F.P., Determinação do albedo e índice de área foliar usando o sensor TM/LANDSAT 5. **Anais XIV Simpósio Brasileiro de Sensoriamento Remoto**, Natal, Brasil, 25-30 abril 2009.

BROWNLEE, J. **A Gentle Introduction to Cross-Entropy for Machine Learning**. 2020. Disponível em: <<https://machinelearningmastery.com/cross-entropy-for-machine-learning/>> Acesso em: 15 nov. 2021.

BROWNLEE, J. **Gradient Descent For Machine Learning**. 2019. Disponível em: <<https://machinelearningmastery.com/gradient-descent-for-machine-learning/>> Acesso em: dez. 2021.

BROWNLEE, J. **How to Avoid Overfitting in Deep Learning Neural Networks**. 2019. Disponível em: <<https://machinelearningmastery.com/introduction-to-regularization-to-reduce-overfitting-and-improve-generalization-error/>> Acesso em: abr. 2022.

BURIOL, G. A.; ESTEFANEL, V.; RIGHI, E. Z.; BRESSAN, V. C. Conforto térmico para os seres humanos nas condições de ambiente natural em Santa Maria, RS, **Brasil. Ciência Rural** [online]. 2015, v. 45, n. 02.

CARVALHO, V. P. Previsão de Séries Temporais no Mercado Financeiro de Ações com o uso de Rede Neural Artificial. 2018. **Dissertação** (Mestrado) Programa de Pós-graduação em Engenharia Elétrica e Computação. Universidade Presbiteriana Mackenzie. 2018.

CATTIVELLI, V. Planning peri-urban areas at regional level: The experience of Lombardy and Emilia-Romagna (Italy), **Land Use Policy**, Volume 103, 2021,

CAVALCANTI, I. F. A.; FERREIRA, N. J.; DIAS, M. A. F.; JUSTI, M. G. A. **Tempo e Clima no Brasil**. 1ed. São Paulo: Oficina de Textos, p. 243 – 258, 2009.

CESCA, R. S., SANTOS, R. C., GOES, R.H.T.B., FAVARIM, A.P.C., OLIVEIRA, M.S.G., SILVA, N.C. Thermal comfort of beef cattle in the state of Mato Grosso do Sul, Brazil. **Ciência e Agrotecnologia (Online)**, v.45, p. e008321, 2021.

CHEN, L.; NG, E. Outdoor thermal comfort and outdoor activities: A review of research in the past decade. **Cities**, n.29, p.118-125, 2011.

CHRISTOPHERSON, R. W. Geossistemas: uma introdução a Geografia Física. 2012. Tradução Francisco Eliseu Aquino, Jefferson Cardia Simões, Ulisses Franz Bremer. Porto Alegre: **Bookman**. 2012.

CORDETS, M.; OMRAN, M.; RAMOS, S.; REHFLD, T.; ENZWEILER, M.; BENENSON, R.; FRANKE, U.; ROTH, S.; SCHIELE, B. The Cityscapes Dataset for Semantic Urban Scene Understanding. **IEEE Xplore**. CVPR, 2016.

CUNHA, C. R. Influência da cobertura do céu nos albedos de uma região de cerrado da baixada cuiabana. 2012. **Dissertação** (mestrado) – Universidade Federal de Mato Grosso, Instituto de Física, Programa de Pós-Graduação em Física Ambiental, Cuiabá.

Data Science Academy. **Deep Learning Book**, 2021. Disponível em: <<https://www.deeplearningbook.com.br/>>. Acesso em: 16 nov. 2021.

DOHERTY, M., KLIMA, K., HELLMANN, J. J. Climate change in the urban environment: Advancing, measuring and achieving resiliency, **Environmental Science & Policy**, Volume 66, 2016, Pages 310-313.

DUFFIE, J. A.; BECKMAN, W. A. Solar Engineering of Thermal Processes. New York: John Wiley; **Sons**, 1980. p. 1-196

EXCEL. Software. Versão: 18.2110.13110.0. Microsoft Corporation. 2021

FERREIRA, M. C. LOPES, J. F. O Crescimento Populacional e os Impactos Ambientais. **Revista Científica Multidisciplinar Núcleo do Conhecimento**. Ano 05, Ed. 06, Vol. 02, pp. 188-195. Junho de 2020.

FRANCO, F. M. Configuração Urbana e sua Interferência no Microclima Local: Estudo de Caso no Bairro do Porto em Cuiabá-MT. 2010. 153f. **Dissertação** (Mestrado em Física Ambiental), Instituto de Física, Universidade Federal de Mato Grosso, Cuiabá, 2010.

FREITAS, R.; AZERÊDO, J. (2020). Do natural ao construído: proposta para estimar acúmulo de calor em metrópoles. **Cadernos Metrópoles**, 23, 331-354.

FRICK, A. D. A. Caracterização de Minério de ferro por Visão Computacional. **Dissertação** (mestrado). Programa de Pós-graduação em Engenharia de Produção. Universidade Federal de Santa Maria, 2008.

FROTA, A. B.; SCHIFFER, S. R. Manual de conforto térmico. São Paulo: **Studio Nobel**, 2001.

GASPERACCO, W., ROCHA, T. S., MAZZOCO, G., FARDIN, J. F., SIMONETTI, D. S. L., Rede Neural Artificial Aplicada ao Rastreamento de Pontos de Máxima Potência de Painéis Fotovoltaicos com Sombreamento Parcial, VIII Encontro Científico de Física Aplicada, Blucher Physics Proceedings, vol. 4, 2017, p. 85-90, ISSN 2358-2359, <http://dx.doi.org/10.1016/phypro-viii-efa-21>.

GOODFELLOW, I. BENGIO, Y. COURVILLE, A. Deep Learning - Ebook. 2016. Disponível em: < <https://www.deeplearningbook.org/> >. Acesso em: maio 2022.

GOOGLE. Google Earth Pro. website. <http://earth.google.com/>, 2021.

GOMES, C. S. IMPACTOS DA EXPANSÃO DO AGRONEGÓCIO BRASILEIRO NA CONSERVAÇÃO DOS RECURSOS NATURAIS. **Cadernos Do Leste**, v.19. n.19. 2019.

HAN, J., KANG, S. Dynamic imputation for improved training of neural network with missing values, **Expert Systems with Applications**, v.194, p. 116508, 2022.

HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Editora Bookman, 2007.

HEATH, G. **What is EPOCH in neural network**. 2013. Disponível em: <https://www.mathworks.com/matlabcentral/answers/62668-what-is-epoch-in-neural-network#answer_74345> Acesso em: 19 nov 2021.

HEATON, J. Artificial Intelligence for Humans, Volume 3: Neural Networks and Deep Learning. **Heaton Research, Inc.** December, 2015.

HECHT-NIELSEN, R. Neurocomputing. Boston: **Addison-Wesley Longman**, 1989.

IBGE - **Instituto Brasileiro de Geografia e Estatística. Censo agropecuário 2017**. Disponível em:<http://www.ibge.gov.br/home/estatistica/economia/agropecuaria/censoagro/brasil_2017/resultadosdefinitivos.pdf> Acesso em: 20 set. 2021.

IBGE - **Instituto Brasileiro de Geografia e Estatística. Painel histórico - 2021**. Disponível em: <<https://www.cidades.ibge.gov.br/painel/historico.php?codmun=500370&search=mato-grosso-do-sul%7Cinphographics:-history&lang=>. Acesso em: 08 set. 2021.

IENCO, D., GAETANO, R., DUPAQUIER, C., MAUREL, P. 2017. Land Cover Classification via Multi-temporal Spatial Data by Recurrent Neural Networks. **IEEE Geoscience and Remote Sensing Letters**. [https://doi: 10.1109/LGRS.2017.2728698](https://doi.org/10.1109/LGRS.2017.2728698)

IPCC, 2014: **Summary for Policymakers. In: Climate Change 2014: Mitigation of climate change**. Contribution of working group III to the fifth assessment report of the intergovernmental panel on climate change. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 2014. Disponível em: <<https://www.ipcc.ch/>>. Acesso em: 07 ago. 2021.

IPCC, 2021: **Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change**. Cambridge University Press. In Press. Cambridge, United Kingdom and New York, NY, USA, 2014. Disponível em: <<https://www.ipcc.ch/>>. Acesso em: 21 set. 2021.

JOHANSSON, E.; THORSSON, S.; EMMANUEL, R.; KRUGER, E. Instruments and methods in outdoor thermal comfort studies – The need for standardization. **Urban Climate**, n.10, p.346-366, 2014.

KAMILARIS, A.; PRENAFETA-BODÚ, F. X. Deep learning in agriculture: A survey. **Computers and Electronics in Agriculture** 147. P. 70 – 90. © 2018 Elsevier B.V.

KHOLWAL, R.; MAURYA, S. A Comparative Approach on Classification of Images with Convolutional Neural Networks. **International Journal of Engineering and Advanced Technology**. 2021

KOECH, K. E. Cross-Entropy Loss Function. **Writer || Data Scientist || Statistician**. 2020 Disponível em: < <https://towardsdatascience.com/cross-entropy-loss-function-f38c4ec8643e>> Acesso em: 15 nov 2021.

LA VINE, F. **How Do Neural Networks Learn?**. Artificially Intelligent. Volume 34 Number 4. April 2019. Disponível em: <<https://docs.microsoft.com/en-us/archive/msdn-magazine/2019/april/artificially-intelligent-how-do-neural-networks-learn#gradiente-descendente-taxa-de-aprendizado-e-gradiente-descendente-estoc%C3%A1stico>> Acesso em: 17 nov 2021.

LAURENTI, A.C. Evolução da ocupação e do rendimento das pessoas no meio rural do Paraná no período 2001- 2009. **Revista Paranaense de Desenvolvimento**, v.124, 2013.

LEDDA, A., SERRA, V., DE MONTIS, A. The Effect of Rural Buildings on Landscape Fragmentation in Natura 2000 Sites: A Case Study in Sardinia. **Sustainability**. v.11, 2019.

LIMA, D. C. R. Forma e arborização em cânions urbanos: tendências de estresse térmico para o pedestre em cenários futuros de Umuarama/PR **Tese (Doutorado)**. Instituto de Arquitetura e Urbanismo de São Paulo, São Carlos, 2017

LIMA, N. G. B. Interação dos atributos climáticos nos manguezais do litoral sul de São Paulo e sua relação com os controles climáticos. 2014. 317f. **Tese (Doutorado)** – Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo, 2014.

LIPPMANN, R.P. An introduction to computing with neural nets. **IEEE ASSP Magazine**, [S.l.], v. 4, n. 2, p. 4-22. 1987.

LOVATTO, J., SANTOS, R. C., SOUZA, C.M.A., ZUCCA, R.; LOVATTO, F., GEISENHOFER, L.O. Use of linear programming for decision making: An analysis of cost, time and comfort of rural housing dwellings. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.24, p.622-629, 2020.

MALINVERNI, M. S. Sistema hipermídia sobre câncer de colo de útero com interface adaptativa usando redes neurais artificiais MLP e sistema especialista. **Dissertação** (mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Pós-Graduação em Engenharia Elétrica. 2006.

MANO, E. B.; PACHECO, É. B. A. V.; BONELLI, C. M.C. **Meio Ambiente, Poluição e Reciclagem**. 1. ed. - São Paulo: Edgard Blücher, 2010.

MARTINS, V. N. Alterações ambientais na região do distrito de Itahum no período de 1986 a 2014. **Dissertação** (Mestrado). Dourados, MS: UFGD, 2015.

MARTINS, J., NOGUEIRA, K., OSCO, L., GOMES, F., FURUYA, D., GONÇALVES, W., SANT'ANA, D., RAMOS, A., LIESENBERG, V., DOS SANTOS, J., OLIVEIRA, P. T., JUNIOR, J. Semantic Segmentation of Tree-Canopy in Urban Environment with Pixel-Wise Deep Learning. **Remote Sensing**. v.13, n.16, p.3054, 2021

MAS, J.F.; FLORES, J.J. The application of artificial neural networks to the analysis of remotely sensed data. **International Journal of Remote Sensing**, 29, pp. 617–663. 2008

MASCARÓ, L.; MASCARÓ, J. **Vegetação urbana**. 2. Ed. Porto Alegre: Mais Quatro editora, 2005.

MATA, C.; FONSECA, K.; MIRANDA, S. **Mudanças climáticas na agricultura do estado de Goiás – Impactos e estratégias**. XXX Congresso Brasileiro de Agronomia – CBA. Janeiro, 2018.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bull Math Biol**, v.5, n.4, p. 115-133, 1943.

MEIRELLES, F.D.P. Modelo computacional de um rebanho bovino de corte virtual utilizando simulação Monte Carlo e redes neurais artificiais. 2005. 104f. **Tese** (Doutorado em Zootecnia) Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, SP.

MELUMAD, S., HADI, R., HILDEBRAND, C., WARD, A. F. Technology-augmented choice: How digital innovations are transforming consumer decision processes. *Customer Needs and Solutions*, v.7, n.3, p. 90-101. 2020.

MENDONÇA, F. A.; DANNI-OLIVEIRA, I. M. **Climatologia: noções básicas e climas do Brasil**. São Paulo: Oficina de Textos, 2007.

MENDONÇA, M. R. M. TEIXEIRA, B. S.; QUADRELLI, G. FRANCISS, R. Rede neural artificial aplicada à estimativa da pressão de poros de uma formação rochosa. **Geologia USP. Série Científica**, v. 21, n. 2, p. 41-58, 2021.

MIRANDA, S. C.; MATA, C. R. FONSECA, K. S.; DE-CARVALHO, P. S. Apontamentos sobre mudanças climáticas na agricultura brasileira. **Enciclopédia Biosfera**, Centro Científico Conhecer - Goiânia, v.15 n.27; p. 95, 2018.

MISHRA, A. Metrics to Evaluate your Machine Learning Algorithm. 2018. Disponível em: <<https://towardsdatascience.com/metrics-to-evaluate-your-machine-learning-algorithm-f10ba6e38234>> Acesso em: jan. 2022.

MURPHY, K. P. Machine Learning: A Probabilistic Perspective. **Cambridge: MIT Press**. p. 247. 2012

NETO, A.; BONINI, C. S. B. REDES NEURAIS ARTIFICIAIS: APRESENTAÇÃO E UTILIZAÇÃO DO ALGORITMO PERCEPTRON EM BIOSISTEMAS. **Revista Brasileira de Engenharia de Biosistemas**. v.4, n.2, p.87-95, 2014.

NIELSEN, M. Neural Networks and Deep Learning. Free online book. 2019. Disponível em: <<http://neuralnetworksanddeeplearning.com/>>. Acesso em: jan. 2022

NINCE, P.C.C. Avaliação de desempenho termo-luminoso em uma escola na cidade de Cuiabá-MT: estudo de caso. 2009. 105 f. **Dissertação** (Mestrado em Física Ambiental), Instituto de Física, Universidade Federal de Mato Grosso, Cuiabá, 2009.

OLIVEIRA, A. S. Influência da vegetação arbórea no microclima e uso de praças públicas. Cuiabá, 146f. **Tese** (Doutorado) - Programa de Pós-graduação em Física Ambiental, Universidade Federal de Mato Grosso. 2011.

OLIVEIRA, A.G. Avaliação das Temperaturas Superficiais do Solo em relação à Conformação Urbana existentes na Praça do Aeroporto Marechal Rondon em Várzea Grande/MT. 80f. **Dissertação** (Mestrado em Física e Meio Ambiente), Departamento de Física, Universidade Federal de Mato Grosso, Cuiabá, 2008.

PAN, F., PEI, J., ZHANG, Z., WEN, Y., ZHANG, Z., LI, R. Building the cooling roads with high thermal conductivity pavements to relieve urban heat island effect, *Construction and Building Materials*, v. 346, p.128276, 2022.

PEIXOTO, L. A. Redes Neurais Artificiais na predição do valor genético. **Dissertação** (Mestrado), Universidade Federal de Viçosa, 97f. Viçosa, MG, 2013

PERLIN, H. A.; LOPES, H. S. Extracting human attributes using a convolutional neural network approach, *Pattern Recognition Letters*, Volume 68, Part 2, pag. 250-259, 2015.

Personal Home Page. Disponível em: <<https://github.com/php/web-php/blob/master/downloads.php>>. Acesso em: 2021.

PYKES, K. The Most Common Evaluation Metrics In NLP - NATURAL LANGUAGE PROCESSING NOTES. 2021. Disponível em: <<https://towardsdatascience.com/the-most-common-evaluation-metrics-in-nlp-ced6a763ac8b>> Acesso em: jan. 2022.

Python 3.7.8 (tags/v3.7.8:4b47a5b6ba, 28 Jun 2020, 08:53:46) [MSC v.1916 64 bit (AMD64)] on win32.

QIU, C., MOU, L., SCHMITT, M., ZHU, X.X. Local climate zone-based urban land cover classification from multi-seasonal Sentinel-2 images with a recurrent residual network. *ISPRS Journal of Photogrammetry and Remote Sensing*. v.154, p. 151-162, 2019

R *Software*. BHERING, L.L. A Tool For Biometric And Statistical Analysis Using The R Platform. *Crop Breeding and Applied Biotechnology*, v.17: 187-190p, 2017. Versão 162: 30/08/2021

RABELLO, E. B. Cross Validation: Avaliando seu modelo de Machine Learning. **Machine Learning Engineering at APPAI**. 2019. Disponível em: <<https://medium.com/@edubrazrabello/cross-validation-avaliando-seu-modelo-de-machine-learning-1fb70df15b78>>. Acesso em: jan. 2022.

RAMÍREZ, C. L. J.; CARMONA, R. F. J.; VICENTE, C. C. M. et al. Analysis of the coexistence of gaming and viewing activities in Twitch users and their relationship with pathological gaming: a multilayer perceptron approach. *Sci Rep* 12, 7904 (2022).

REIS, B. **Redes neurais - Funções de ativação**. 2016.

REHEM, A.; TRINDADE, F. H. V., **Técnicas de Visão Computacional para Rastreamento de Olhar em Vídeos**. 2010.

RHODEN, A. C., VIANA, J. G. A., SILVEIRA, V. C. P. Mudança no uso da terra e dinâmica econômica da Área de Proteção Ambiental do Rio Ibirapuitã do bioma Pampa brasileiro. *Semina: Ciências Agrárias*, v.43, n.5, p.2137–2154, 2022.

RODRIGUES, V. C. **Distribuição especial e bem-estar de aves poedeiras em condições de estresse e conforto térmico utilizando visão computacional e inteligência artificial** — Piracicaba 2006.

ROMERO, M. A. B. *Arquitetura Bioclimática do Espaço Público*. Brasília-DF, **Editora Universidade de Brasília**, 2007.

ROTH, M. Review of urban climate research in (sub)tropical regions. **International journal of Climatology**. v. 27, n. 14, p. 185-187, 2007.

ROSSI, F. A.; KRUGUER, E.; NIKOLOPOULOU, M. A influência da configuração urbana no microclima e na sensação térmica em ruas de pedestre de Curitiba, Paraná. In: XI Encontro Nacional e VII Latino-americano de Conforto no Ambiente Construído - ENCAC/ELACAC, 2011, Búzios. **Anais...** Búzios: ANTAC, 2011.

RIBEIRO, K. F. A. Análise da influência da vegetação arbórea no comportamento térmico dos diferentes tipos de revestimento do solo. Cuiabá, 2016. 156f. **Dissertação** (Mestrado) - Programa de Pós-graduação em Física Ambiental, Universidade Federal de Mato Grosso.

RIBEIRO, K., JUSTI, A., SANTOS, F., PAULA, D., NOGUEIRA, M., SOUZA, N., ALVES, K. Análise do índice UTCI em diferentes tipos de cobertura na cidade de Cuiabá, Mato Grosso. **Revista Brasileira de Climatologia**. v.28. 2021.

RUSSEL, B. C.; TORRALBA, A.; MURPHY, K. P.; FREEMAN, W. T. LabelMe: a database and web-based tool for image annotation. **International Journal of Computer Vision**. Vol. 77, ISSUE 1-3, PAGES 157-173, MAY 2008.

- RUSSO, J. G. J. Processo de terceirização na universidade federal da grande Dourados unidade II: um estudo de caso. **Dissertação** (Mestrado), Universidade Federal da Grande Dourados, 2019.
- SANTOS, F. A.; AQUINO, C. M. S. Análise da precipitação pluviométrica no município de Castelo do Piauí, Nordeste do Brasil. *Geosp*, 21(2), 619-633. 2017.
- SANTOS, P. H. A. B.; DELFINO, O. A. dos S.; SANTOS, R. V. R. dos; NASCIMENTO, M. do. Adjustment of a time series model to predict rainfall Research, Society and Development, [S. l.], v. 10, n. 6, p. e41810615643, 2021.
- SCALABRIN, M. H. Aplicação de Redes Neurais Artificiais Profundas na Detecção de Placas De Pare. 53p. **Monografia** (Especialização em Métodos Matemáticos Aplicados) - Universidade Tecnológica Federal do Paraná. Francisco Beltrão, 2019.
- SHAH, R., PANDIT, K. R., GAUR, M.K. Thermal comfort analysis through development of artificial neural network models: An experimental study in Cwa climate, **Materials Today: Proceedings**, v. 57, Part 5, p. 2018-2025, 2022.
- SEN, S., ROESLER, J. Thermal and optical characterization of asphalt field cores for microscale urban heat island analysis, *Construction and Building Materials*, v. 217, p. 600-611, 2019,
- SHARMA, S. What the Hell is Perceptron? The Fundamentals of Neural Networks. **Deep learning/AI Electronics**. 2017. Disponível em: <<https://towardsdatascience.com/what-the-hell-is-perceptron-626217814f53>>. Acesso em: jan. 2022.
- SHEELA, K. G.; DEEPA, S. N. Review on Methods to Fix Number of Hidden Neurons in Neural Networks. Anna University, Regional Centre, Coimbatore 641047, India. 2013
- SILVA, T. J. V. Calibração do Universal Thermal Climate Index (UTCI) para Espaços Abertos do Município de Belo Horizonte, Minas Gerais. **Dissertação de Mestrado**. PPGEC-CEFET.MG – Programa de Pós-Graduação em Engenharia Civil do Centro Federal de Educação Tecnológica de Minas Gerais. 2019.
- SIMA, W.; ZHANG, H.; YANG, M.; LI, X. Diagnosis of small-sample measured electromagnetic transients in power system using DRN-LSTM and data augmentation, **International Journal of Electrical Power & Energy Systems**, Volume 137, 2022.
- SMALCI, A.; SILVA, O. R.; FERNANDES, C. A.; QUEL, L. F. FATORES DETERMINANTES E CONDICIONANTES PARA INOVAÇÃO E COMPETITIVIDADE NO SETOR DO AGRONEGÓCIO BRASILEIRO. **Revista Metropolitana de Sustentabilidade** (ISSN 2318-3233), São Paulo, v. 10, n. 1, p. 6, 2020. Disponível em: <http://revistaseletronicas.fmu.br/index.php/rms/article/view/2250>. Acesso em: 18 maio. 2022.
- SOARES, P. L. B. SILVA, J. P. Aplicação de Redes Neurais Artificiais em Conjunto com o Método Vetorial da Propagação de Feixes na Análise de um Acoplador Direcional Baseado em Fibra Ótica. **Revista Brasileira de Computação Aplicada** (ISSN 2176-6649), Passo Fundo, v.3, n.2, p.58-72, set. 2011.
- SOUZA, N., NOGUEIRA, M., SANTOS F., SANCHES, L. Urban Heat and Urban Cool Islands of Different Land Use Types in Cuiabá, Brazil. **Research Square**; 2021.

SPÖRL, C.; CASTRO, E. G.; LUCHIARI, A. Aplicação de Redes Neurais Artificiais na Construção de Modelos de Fragilidade Ambiental. **Revista do Departamento de Geografia – USP**, Volume 21, p.113-135. 2011.

STATHAKIS, D. How many hidden layers and nodes?. **International Journal of Remote Sensing**. Vol. 30, No. 8, 20 April 2009, 2133–2147.

SURMENOK, P. Estimating na Optimal Learning Rate For a Deep Neural Network. **Machine learning engineering and self-driving cars**. 2017. Disponível em: <<https://towardsdatascience.com/estimating-optimal-learning-rate-for-a-deep-neural-network-ce32f2556ce0>> Acesso em: abril 2022.

TAKANO, W. H.; ALMEIDA, L. L.; DA SILVA, F. A. Detecção de animais bovinos utilizando imagens aéreas por meio de redes neurais. In: **Colloquium Exactarum**. ISSN: 2178-8332. 2021. p. 47-56.

TRINDADE, L. L. Detecção de obstáculos para carros autônomos utilizando aprendizado profundo. 87 p. Monografia (graduação) - Universidade Federal de Santa Catarina, Centro Tecnológico, Graduação em Engenharia Elétrica, Florianópolis, 2018.

THOM, E.C. **Disconfort index Londres: Weatherwise**. p. 57 – 61, 1959.

VAREJÃO, M. A. **Meteorologia e Climatologia**. Recife, Pernambuco Brasil Março de 2006.

VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações**. Viçosa: UFV, 2000.

Visual Studio Code. Version: 1.62.2 (user setup). 11 agosto 2021.

Wang, H., You, Q., Liu, G., Wu, F. Climatology and trend of tourism climate index over China during 1979–2020. *Atmospheric Research*. v.277, p.106321, 2022,

YANAGI JUNIOR, T.; SCHIASSI, L.; ABREU, L. H.; BARBOSA, J. A.; CAMPOS, A. T. Procedimento fuzzy aplicado à avaliação da insalubridade em atividades agrícolas. **Engenharia Agrícola**, v.32, n.3, p.423-434, 2012.

ANEXO 1 - Script utilizado na extração das características dos elementos paisagísticos das imagens RGBs convertidas em *Ground Truth*

```

<?php
$num_results = (! empty($_POST['num_results'])) ? $_POST['num_results'] : 10;
$delta = (! empty($_POST['delta'])) ? $_POST['delta'] : 40;
$reduce_brightness      =      (isset($_POST['reduce_brightness']))      ?
$_POST['reduce_brightness'] : 1;
$reduce_gradients      =      (isset($_POST['reduce_gradients']))      ?
$_POST['reduce_gradients'] : 1;

include_once("colors.inc.php");
$ex=new GetMostCommonColors();
$colors=$ex->Get_Color("test.JPG",      $num_results,      $reduce_brightness,
$reduce_gradients, $delta);
?>
<!DOCTYPE html>
<html xmlns="http://www.w3.org/1999/xhtml" lang="en" xml:lang="en">
<head>
    <title>Adaptação extração de cores</title>
    <style type="text/css">
        * {margin: 0; padding: 0}
        body {text-align: center;}
        form, div#wrap {margin: 10px auto; text-align: left; position: relative;
width: 500px;}

        fieldset {padding: 20px; border: solid #999 2px;}
        img {width: 200px;}
        table {border: solid #000 1px; border-collapse: collapse;}
        td {border: solid #000 1px; padding: 2px 5px; white-space: nowrap;}
        br {width: 100%; height: 1px; clear: both; }
    </style>
</head>
<body>
<div id="wrap">

```

```

<form action="#" method="post" enctype="multipart/form-data">
<fieldset>
<legend>Carrega suas imagens manualmente</legend>
<div>
    <label>File: <input type="file" name="imgFile" /></label>
</div>
<div>
    <label>Number of colors: <input type="text" name="num_results"
value="<?=$num_results?>" /></label>
</div>
<div>
    <label>delta: <input type="text" name="delta" value="<?=$delta?>" /></label>
</div>
<div>
    <label>Reduce brightness: <input type="radio" name="reduce_brightness"
value="1" <?php if ($reduce_brightness) {?>checked="checked"<?php } ?> /> Yes <input
type="radio" name="reduce_brightness" value="0" <?php if (! $reduce_brightness)
{?>checked="checked"<?php } ?> /> No</label>
</div>
<div>
    <label>Reduce gradients: <input type="radio" name="reduce_gradients" value="1"
<?php if ($reduce_gradients) {?>checked="checked"<?php } ?> /> Yes <input type="radio"
name="reduce_gradients" value="0" <?php if (! $reduce_gradients)
{?>checked="checked"<?php } ?> /> No </label>
</div>
<div>
    <input type="submit" name="action" value="Process" />
</div>
</fieldset>
</form>
<?php
// was any file uploaded?
if ( isset( $_FILES['imgFile']['tmp_name'] ) && strlen(
$_FILES['imgFile']['tmp_name'] ) > 0 )

```

```

{
    // move image to a writable directory
    if (!move_uploaded_file($_FILES['imgFile']['tmp_name'],
'images/'.$_FILES['imgFile']['name']))
    {
        die("Error moving uploaded file to images directory");
    }
    $colors=$ex->Get_Color( 'images/'.$_FILES['imgFile']['name'], $num_results,
$reduce_brightness, $reduce_gradients, $delta);
?>
<table>
<tr><td>Color</td><td>Color Code</td><td>Percentage</td><td rowspan="<?php
echo (($num_results > 0)?($num_results+1):22500);?>"></td></tr>
<?php
foreach ( $colors as $hex => $count )
{
    if ( $count > 0 )
    {
        echo "<tr><td style=\"background-
color:#".$hex.";\"></td><td>".$hex."</td><td>$count</td></tr>";
    }
}
?>
</table>
<br />
<?php
}
?>

<?php
$colors=$ex->Get_Color("images/1A_Output.JPG", $num_results,
$reduce_brightness, $reduce_gradients, $delta);
?>

```

```

<table>
  <tr><td>Color</td><td>Color Code</td><td>Percentage</td><td rowspan="<?php
echo (($num_results > 0)?($num_results+1):22500);?>"></td></tr>

  <?php
  foreach ( $colors as $hex => $count )
  {
    if ( $count > 0 )
    {
      echo          "<tr><td          style=\"background-
color:#\".$hex.\";\"></td><td>\".$hex.\"</td><td>$count</td></tr>";
    }
  }
?>
</table>
<br />

<?php
$colors=$ex->Get_Color("images/1B_Output.JPG",          $num_results,
$reduce_brightness, $reduce_gradients, $delta);
?>
<table>
  <tr><td>Color</td><td>Color Code</td><td>Percentage</td><td rowspan="<?php
echo (($num_results > 0)?($num_results+1):22500);?>"></td></tr>

  <?php
  foreach ( $colors as $hex => $count )
  {
    if ( $count > 0 )
    {
      echo          "<tr><td          style=\"background-
color:#\".$hex.\";\"></td><td>\".$hex.\"</td><td>$count</td></tr>";
    }
  }
}

```

```

?>
</table>
<br />

<?php
    $colors=$ex->Get_Color("images/1C_Output.JPG",                $num_results,
    $reduce_brightness, $reduce_gradients, $delta);
?>
<table>
    <tr><td>Color</td><td>Color Code</td><td>Percentage</td><td rowspan="<?php
echo (($num_results > 0)?($num_results+1):22500);?>"></td></tr>
    <?php
    foreach ( $colors as $hex => $count )
    {
        if ( $count > 0 )
        {
            echo                "<tr><td                style=\"background-
color:#".$hex.";\></td><td>".$hex."</td><td>$count</td></tr>";
        }
    }
?>
</table>
<br />

<?php
    $colors=$ex->Get_Color("images/2A_Output.JPG",                $num_results,
    $reduce_brightness, $reduce_gradients, $delta);
?>
<table>
    <tr><td>Color</td><td>Color Code</td><td>Percentage</td><td rowspan="<?php
echo (($num_results > 0)?($num_results+1):22500);?>"></td></tr>
    <?php

```

```

foreach ( $colors as $hex => $count )
{
    if ( $count > 0 )
    {
        echo "
|  |  |  |  |  |  | | | | | |
|---|---|---|---|---|---|---|---|---|---|---|
| Color | Color Code | Percentage | <?php echo (($num_results > 0)?($num_results+1):22500);?> </td></tr> <?php foreach ( $colors as $hex => $count ) {     if ( $count > 0 )     {         echo " |  | | --- | |  | | |

```

```

?>
<table>
  <tr><td>Color</td><td>Color Code</td><td>Percentage</td><td rowspan="<?php
echo (($num_results > 0)?($num_results+1):22500);?>"></td></tr>

  <?php
  foreach ( $colors as $hex => $count )
  {
    if ( $count > 0 )
    {
      echo "
      <tr><td style=\"background-
color:#\".$hex.\";\"></td><td>\".$hex.\"</td><td>$count</td></tr>";
    }
  }?>
</table>
<br />

<?php
$colors=$ex->Get_Color("images/3A_Output.JPG", $num_results,
$reduce_brightness, $reduce_gradients, $delta);
?>
<table>
  <tr><td>Color</td><td>Color Code</td><td>Percentage</td><td rowspan="<?php
echo (($num_results > 0)?($num_results+1):22500);?>"></td></tr>

  <?php
  foreach ( $colors as $hex => $count )
  {
    if ( $count > 0 )
    {
      echo "
      <tr><td style=\"background-
color:#\".$hex.\";\"></td><td>\".$hex.\"</td><td>$count</td></tr>";
    }
  }?>

```

```

</table>
<br />

<?php
    $colors=$ex->Get_Color("images/3B_Output.JPG",                $num_results,
$reduce_brightness, $reduce_gradients, $delta);
    ?>
    <table>
        <tr><td>Color</td><td>Color Code</td><td>Percentage</td><td rowspan="<?php
echo (($num_results > 0)?($num_results+1):22500);?>"></td></tr>
        <?php
        foreach ( $colors as $hex => $count )
        {
            if ( $count > 0 )
            {
                echo                "<tr><td                style=\"background-
color:#".$hex.";\></td><td>".$hex."</td><td>$count</td></tr>";
            }
        }
    ?>
</table>
<br />
<?php
    $colors=$ex->Get_Color("images/3C_Output.JPG",                $num_results,
$reduce_brightness, $reduce_gradients, $delta);
    ?>
    <table>
        <tr><td>Color</td><td>Color Code</td><td>Percentage</td><td rowspan="<?php
echo (($num_results > 0)?($num_results+1):22500);?>"></td></tr>
        <?php
        foreach ( $colors as $hex => $count )
        {

```

```

        if ( $count > 0 )
        {
            echo "
|  |  |
| --- | --- |
| " . $hex . "  $count | |

";
        }
    }
?>
</table>
<br />
</div>
</body>
</html>

```

ANEXO 2 - Script 1 da Rede Neural Artificial

```
import os
from numpy import dtype
import torch
from torch import nn
from torch._C import wait
from torchvision.datasets import CIFAR10
from torch.utils.data import DataLoader
from torchvision import transforms
import ssl
import pandas as pd
import torch
from torch.utils.data import Dataset
from sklearn.preprocessing import scale
import matplotlib.pyplot as plt
import numpy as np
```

```
class MLP(nn.Module):
    """
    Multilayer Perceptron.
    """
    def __init__(self):
        super().__init__()
        self.layers = nn.Sequential(
            nn.Flatten(),
            nn.Linear(12, 18),
            nn.ReLU(),
            nn.Linear(18, 18),
            nn.ReLU(),
            nn.Linear(18, 5)
        )

    def forward(self, x):
```

```

    """Forward pass"""
    return self.layers(x)

```

```

class AmbientDataset(Dataset):

```

```

    """Face Landmarks dataset."""

```

```

    def __init__(self, fileName, begin, end):

```

```

        """

```

```

        Args:

```

```

            csv_file (string): Caminho para o arquivo csv com anotações.

```

```

            begin (number): definição do número da linha para começar a carregar os dados

```

```

            end (number): definição do número da última linha carregada

```

```

        """

```

```

        self.ambients = pd.read_csv(fileName, ";")

```

```

        x = self.ambients.iloc[begin:end, 0:12]

```

```

        y = self.ambients.iloc[begin:end, 12:]

```

```

        # Dimensionando os recursos

```

```

        # 2D data sc = StandardScaler()

```

```

        #x_train = scale(x)

```

```

        # Convertendo para tensor torch

```

```

        self.x_train = torch.tensor(x.to_numpy(), dtype=torch.float32)

```

```

        self.y_train = torch.tensor(y.to_numpy())

```

```

    def __len__(self):

```

```

        return len(self.x_train)

```

```

    def __getitem__(self, idx):

```

```

        return self.x_train[idx], self.y_train[idx]

```

```

if __name__ == '__main__':

```

```

    ssl._create_default_https_context = ssl._create_unverified_context

```

```

# Definição número aleatório fixo
torch.manual_seed(42)

# Preparação do conjunto de dados
dataset = CIFAR10(os.getcwd(), download=True,
transform=transforms.ToTensor())

dataset1=AmbientDataset('data2.csv',1,181)#training set = 80%
dataset2=AmbientDataset('data2.csv',182,232)#teste set = 20%
# dados divididos para aprendizado e teste

trainloader = torch.utils.data.DataLoader(dataset1, batch_size=10, shuffle=True)

# Inicialização do MLP
mlp = MLP()

# Definição da função de perda e o otimização
loss_function = nn.CrossEntropyLoss()
optimizer = torch.optim.Adam(mlp.parameters(), lr=1e-4)

#histórico
lossArray=[]# armazena o valor da perda para cada época
accArray=[]# armazena o valor da acurácia para cada época

EpochMax=2000# valor de época máximo
# Executar o loop de treinamento
for epoch in range(0, EpochMax): # x épocas no máximo

    # Imprimir época
    epoch+1
    #print(f'Starting epoch {epoch+1}')

    # Definição do valor de perda atual
    current_loss = 0.0

```

```

accuracy=0.0 # acurácia média
# Iteração sobre o DataLoader para dados de treinamento
para recursos, de rótulos no trainloader:
    # Obtendo entradas
    inputs = features

    # Zerando os gradientes
    optimizer.zero_grad()

    # Executando passe para frente
    outputs = mlp(inputs)

    #print(torch.max(labels, 1))

    #a = input("").split(" ")[0]
    #print(a)
    #print(labels.squeeze(1))
    #a = input("").split(" ")[0]
    #print(a)

    # Calculo da perda
    loss = loss_function(outputs,labels.squeeze(1))#, torch.max(labels, 1)[1])

    # Executando passe para trás
    loss.backward()

    # Realizando a otimização
    optimizer.step()

    # Calculo e impressão das estatísticas

    # soma da perda atual para calcular a perda média no lote
    current_loss+= loss.item() #loss.item calcula a perda média dos insumos no lote

```

Cálculo de acurácia simples (acerta se a classe (vem do output) com maior probabilidade for igual ao esperado (rótulos))

```
train_acc = torch.sum(outputs == labels)
```

i=0# índice do seguinte para

```
#print(labels,outputs)
```

for output in outputs:

```
    outL=output.tolist()#converter manualmente tensor para lista
```

```
    #print (outL.index(max(outL)))# procure a classe com maior probabilidade
```

```
    #print(outL)
```

#print('expected',labels[i].numpy()[0])#[0] para obter a entrada esperada, pois numpy retorna uma matriz com um número

```
        if(outL.index(max(outL))==labels[i].numpy()[0]):
```

```
            accuracy=accuracy+1
```

```
        i=i+1
```

```
    if epoch%200==0:
```

```
        #a = input(" ").split(" ")[0]
```

```
        print('Loss after mini-batch %5d: %.3f' %
```

```
              (epoch + 1, current_loss))
```

```
    lossArray.append(current_loss/180)
```

accArray.append((accuracy/180))#número de acertos dividido pelo tamanho da amostra de treinamento

Processo de treinamento está completo.

```
print("Training process has finished.")
```

```
print("Test process has finished.")
```

```
#a = input(" ").split(" ")[0]
```

```
N = np.arange(0, EpochMax)
```

```
plt.style.use("ggplot")
```

```
plt.figure()
```

```
plt.plot(N, lossArray , label="erro_treinamento")
```

```
plt.plot(N, accArray, label="precisão_treinamento")
```

```

plt.title("Erro e Precisão no Treinamento(simple_multiclass_classification)")
plt.xlabel("Época #")
plt.ylabel("Erro/Precisão")
plt.legend()
plt.savefig("training_performance.png")
print("Test process has begun.")
trainloader = torch.utils.data.DataLoader(dataset2, batch_size=10, shuffle=True)
current_loss=0
testacc=0
lossArray.clear()
accArray.clear()
contTest=0# tamanho total da amostra de dados de teste
for features, labels in trainloader:
    i=0
    inputs = features
    outputs = mlp(inputs)
    print(outputs,labels)
    loss = loss_function(outputs,labels.squeeze(1))
    for output in outputs:
        outL=output.tolist()#índice é sempre 0, apenas uma amostra no lote
        expected=labels[i].numpy()[0]
        obtained=outL.index(max(outL))
        print(expected,obtained,expected==obtained)
        if(expected==obtained):
            testacc=testacc+1
            #a = input("").split(" ")[0]
            #print(testacc)
        i=i+1
    lossArray.append(loss.item())
    accArray.append(testacc/10)# tamanho do lote
    testacc=0
    contTest=contTest+1
    print(labels)
    print('Error  %5d: %.3f' %

```

```
(contTest+1, loss))
#a = input("").split(" ")[0]
print("perda",lossArray,"acura",accArray)
#a = input("").split(" ")[0]
print("conte me",contTest)
#a = input("").split(" ")[0]
N = np.arange(0, contTest)
plt.style.use("ggplot")
plt.figure()
plt.xticks(range(0,contTest))
plt.plot(N, lossArray , label="erro_operação")
plt.plot(N, accArray, label="precisão_operação")
plt.title("Erro e Precisão no Teste")
plt.xlabel("Batch # (Lote de teste)")
plt.ylabel("Erro/Precisão")
plt.legend()
plt.savefig("testing_performance.png")
```

ANEXO 3 - Script 2 da Rede Neural Artificial

```
import os
from numpy import dtype
import torch
from torch import nn
from torch._C import wait
from torchvision.datasets import CIFAR10
from torch.utils.data import DataLoader
from torchvision import transforms
import ssl
import pandas as pd
import torch
from torch.utils.data import Dataset
from sklearn.preprocessing import scale
import matplotlib.pyplot as plt
import numpy as np
```

```
class MLP(nn.Module):
    """
    Multilayer Perceptron.
    """
    def __init__(self):
        super().__init__()
        self.layers = nn.Sequential(
            nn.Flatten(),
            nn.Linear(11, 18),
            nn.ReLU(),
            nn.Linear(18, 18),
            nn.ReLU(),
            nn.Linear(18, 5)
        )
```

```
def forward(self, x):
    """Forward pass"""
    return self.layers(x)
```

```
class AmbientDataset(Dataset):
    """Face Landmarks dataset."""
```

```
def __init__(self, fileName, begin, end):
    """
```

```
    Args:
```

```
        csv_file (string): Caminho para o arquivo csv com anotações.
```

```
        begin (number): definição do número da linha para começar a carregar os dados
```

```
        end (number): definição do número da última linha carregada
```

```
    """
```

```
    self.ambients = pd.read_csv(fileName, ";")
```

```
    x = self.ambients.iloc[begin:end, 0:11]
```

```
    y = self.ambients.iloc[begin:end, 11]
```

```
    # Dimensionando recursos
```

```
    # 2D data sc = StandardScaler()
```

```
    # x_train = scale(x)
```

```
    # convertendo para tensores torch
```

```
    self.x_train = torch.tensor(x.to_numpy(), dtype=torch.float32)
```

```
    self.y_train = torch.tensor(y.to_numpy())
```

```
def __len__(self):
```

```
    return len(self.x_train)
```

```
def __getitem__(self, idx):
```

```
    return self.x_train[idx], self.y_train[idx]
```

```
if __name__ == '__main__':
```

```

ssl._create_default_https_context = ssl._create_unverified_context

# Definição do número aleatório fixo
torch.manual_seed(72)

# Preparação do conjunto de dados
#dataset          =          CIFAR10(os.getcwd(),          download=True,
transform=transforms.ToTensor())

dataset1=AmbientDataset('dataRd.csv',2,210)#training set = 90%
dataset2=AmbientDataset('dataRd.csv',211,235)#teste set = 10%
# dados divididos para aprendizado e teste

trainloader = torch.utils.data.DataLoader(dataset1, batch_size=10, shuffle=True)

# Inicialização do MLP
mlp = MLP()

# Definição da função de perda e o otimização
loss_function = nn.CrossEntropyLoss()
optimizer = torch.optim.Adam(mlp.parameters(), lr=(1e-4*2))

#histórico
lossArray=[]# armazena o valor da perda para cada época
accArray=[]# armazena o valor da acurácia para cada época

EpochMax=4000# valor de época máximo
# Executar o loop de treinamento
for epoch in range(0, EpochMax): # x épocas no máximo
    # Imprimir época
    epoch+1

```

```

#print(f'Starting epoch {epoch+1}')

# Definição do valor de perda atual
current_loss = 0.0
accuracy=0.0 #acurácia média
# Iteração sobre o DataLoader para dados de treinamento
para recursos, rótulos no trainloader:
    # Obtendo entradas
    inputs = features

# Zerando os gradientes
optimizer.zero_grad()

# Executando passe para frente
outputs = mlp(inputs)

#print(torch.max(labels, 1))

#a = input("").split(" ")[0]
#print(a)
#print(labels.squeeze(1))
#a = input("").split(" ")[0]
#print(a)

# Calculo da perda
loss = loss_function(outputs,labels)#, torch.max(labels, 1)[1])

# Executando passe para trás
loss.backward()

# Realizando a otimização
optimizer.step()

```

```

# calculo e imprissão das estatísticas

# soma da perda atual para calcular a perda média no lote
current_loss+= loss.item() # loss.item calcula a perda média dos insumos no lote

# cálculo de acuracia mais simples (acerta se a classe (vem do output) com maior
probabilidade for igual ao esperado (rótulo))

i=0# índice do seguinte para
#print(labels,outputs)
for output in outputs:
    outL=output.tolist() # converter manualmente tensor para lista
    #print (outL.index(max(outL)))# procurar a classe com maior probabilidade
    #print(outL)
    #print('expected',labels[i].numpy()[0])#[0] para obter a entrada esperada, pois
numpy retorna uma matriz com um número
    if(outL.index(max(outL))==labels[i].numpy()):
        accuracy=accuracy+1
    i=i+1
if epoch%200==0:
    #a = input("").split(" ")[0]
    print('Loss after mini-batch %5d: %.3f %
        (epoch + 1, current_loss))

lossArray.append(current_loss/180)
accArray.append((accuracy/180)) #número de acertos dividido pelo tamanho da
amostra de treinamento

# Processo de treinamento está completo.
print("Training process has finished.")

print("Test process has begun.")
#a = input("").split(" ")[0]

```

```

N = np.arange(0, EpochMax)
plt.style.use("ggplot")
plt.figure()
plt.plot(N, lossArray , label="erro_treinamento")
plt.plot(N, accArray, label="precisão_treinamento")
plt.title("Erro e Precisão no Treinamento(simple_multiclass_classification)")
plt.xlabel("Época #")
plt.ylabel("Erro/Precisão")
plt.legend()
plt.savefig("training_performance.png")
print('Test process has begun.')
trainloader = torch.utils.data.DataLoader(dataset2, batch_size=1, shuffle=True)
current_loss=0
testacc=0
lossArray.clear()
accArray.clear()
contTest=0# tamanho total da amostra de dados de teste
i=0
for features, labels in trainloader:
    inputs = features
    outputs = mlp(inputs)
    loss = loss_function(outputs,labels)
    for output in outputs:
        outL=output.tolist()#índice é sempre 0, apenas uma amostra no lote
        expected=labels[0].numpy()
        obtained=outL.index(max(outL))
        #print("entrada",features[i].tolist(),"saidas          da          rede",outL,"classe
esperada",expected)
        formattedFeatures=['%.2f' % elem for elem in features[0].tolist()#converter para
dois decimais
        #formattedOutput=['%.2f' % elem for elem in outL]# converter para dois decimais
        print("entradas ",formattedFeatures," saidas "," ".join(format(x, ".2f") for x in
outL)," esperada ",expected," retornada ",obtained," Cross_entropy_loss ",loss.item())
        #print(expected,obtained,expected==obtained)

```

```

if(expected==obtained):
    testacc=testacc+1
    #a = input("").split(" ")[0]
    #print(testacc)
i=i+1
lossArray.append(loss.item())
accArray.append(testacc)
#testacc=0
contTest=contTest+1
#print('Error  %5d: %.3f' %
#      (contTest+1, loss))
print("\n Acuracia",testacc/i,"Entropia",sum(lossArray) / len(lossArray))
#a = input("").split(" ")[0]
#print("perda",lossArray,"acura",accArray)
#a = input("").split(" ")[0]
#print("conte me",contTest)
#a = input("").split(" ")[0]
N = np.arange(0, contTest)
plt.style.use("ggplot")
plt.figure()
plt.xticks(range(0,contTest))
plt.plot(N, lossArray , label="erro_operação")
plt.title("Erro no Teste")
plt.xlabel("Batch # (Lote de teste)")
plt.ylabel("Erro")
plt.legend()
plt.savefig("testing_erro.png")
N = np.arange(0, contTest)
plt.style.use("ggplot")
plt.figure()
plt.xticks(range(0,contTest))
plt.plot(N, accArray , label="erro_operação")
plt.title("Precisão no Teste")
plt.xlabel("Batch # (Lote de teste)")

```

```
plt.ylabel("Acurácia")  
plt.legend()  
plt.savefig("testing_performance.png")
```