



Universidade Federal da Bahia
Escola Politécnica
Colegiado do Curso de Eng. da
Computação



Matheus Oliver de Carvalho Cerqueira

Redes Neurais de Classificação e Regressão Aplicadas no Contexto de Iluminação Pública

Orientador: Prof. Dr. Antônio Carlos Fernandes Lopes Jr
Coorientador: Prof. Msc. Wild Freitas da Silva Santos

Salvador-Ba – Brasil
15 de dezembro de 2023

Matheus Oliver de Carvalho Cerqueira

Redes Neurais de Classificação e Regressão Aplicadas no Contexto de Iluminação Pública

Monografia apresentada ao Curso de Graduação em Engenharia da Computação da Universidade Federal da Bahia como parte dos requisitos para a obtenção do grau de Engenheiro de Computação.

Orientador: Prof. Dr. Antônio Carlos Fernandes Lopes Jr

Coorientador: Prof. Msc. Wild Freitas da Silva Santos

Salvador-Ba – Brasil

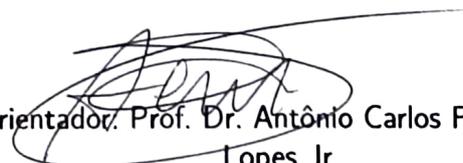
15 de dezembro de 2023

Matheus Oliver de Carvalho Cerqueira

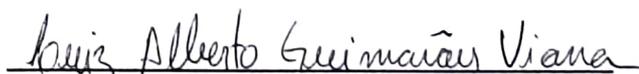
Redes Neurais de Classificação e Regressão Aplicadas no Contexto de Iluminação Pública

Monografia apresentada ao Curso de Graduação em Engenharia da Computação da Universidade Federal da Bahia como parte dos requisitos para a obtenção do grau de Engenheiro de Computação.

Trabalho aprovado. Salvador-Ba – Brasil, 15 de dezembro de 2023:


Orientador. Prof. Dr. Antônio Carlos Fernandes
Lopes Jr


Prof. Dr. Kléber Freire da Silva


Msc. Luiz Alberto Guimarães Viana

Salvador-Ba – Brasil
15 de dezembro de 2023

Agradecimentos

Gostaria de expressar meus sinceros agradecimentos ao meu orientador, Antônio, e coorientador, Wild, cujo apoio foi fundamental para a conclusão desta monografia dentro do prazo previsto.

Sou imensamente grato à minha mãe, Agla, e ao meu pai, Paulo, por estarem ao meu lado desde antes do primeiro dia de aula. Seu apoio constante e encorajamento foram essenciais para me fortalecer ao longo desta jornada.

À minha noiva, Brenda, meu profundo agradecimento por ser minha companheira, incentivadora, revisora incansável e pelo seu apoio incondicional em todos os momentos.

Por fim, mas não menos importante, agradeço às 3.270 versões de mim mesmo que viveram cada dia desde o início da graduação até este ponto. Rindo, chorando, motivando-se, superando desafios, cada uma dessas versões contribuiu para que eu estivesse aqui hoje.

Resumo

A relevância da iluminação pública para vários aspectos cotidianos como segurança e mobilidade motiva a utilização de tecnologias que aperfeiçoem a prestação do serviço à população nas diversas fases de implementação. Como complemento aos *softwares* especializados em simulações, propõe-se, neste trabalho, utilizar técnicas de aprendizado de máquina para garantir a conformidade com os padrões de projetos, expostos na Norma Brasileira 5101. Explorando os conceitos relacionados a iluminação pública e redes neurais, são implementados *Multilayer Perceptron (MLP)* utilizando *backpropagation*, de regressão, para determinar parâmetros de Iluminância e sua uniformidade (requisitos parciais ao atendimento da norma) e classificação (que utiliza os valores de iluminância e sua uniformidade para definir adequação à norma). Os modelos são treinados e testados com parâmetros reais de configurações de malha e de dispositivos luminosos em simulações de projetos para informar se um conjunto de dados de projeto está adequado aos padrões estabelecidos pela norma. Os *MLPs* de regressão e classificação conseguiram MSE de 0,002 e 97,26% de acurácia, respectivamente.

Palavras-chave: iluminação pública. redes neurais artificiais. Multilayer Perceptron. backpropagation.

Abstract

The relevance of public lighting for various everyday aspects such as security and mobility motivates the use of technologies that improve service provision to the population in the many implementation phases. As a complement to software specialized in simulations, this work proposes to use learning machine techniques to ensure compliance with Brazilian Standard 5101. Exploring concepts related to public lighting and networks neural networks, Multilayer Perceptron (MLP) is implemented using backpropagation, for regression, to determine illuminance parameters and their uniformity (requirements partial compliance with the standard) and classification (which uses illuminance and its uniformity to define compliance to the standard). Models are trained and tested with real parameters of mesh configurations and lighting devices in simulations of projects to inform whether a project data set meets standards established by the standard. Regression and classification MLPs achieved MSE of 0.002 and 97.26% accuracy, respectively.

Keywords: public street lighting. artificial neural networks. Multilayer Perceptron. back-propagation.

Lista de ilustrações

Fig. 1 – Ilustração dos conceitos relativos a posicionamento.	26
Fig. 2 – Hierarquia de aprendizado.	31
Fig. 3 – Demonstração da conexão entre neurônios de diferentes camadas.	33
Fig. 4 – Exemplos de funções de ativação.	33
Fig. 5 – Exemplo de função de Ativação ReLU.	33
Fig. 6 – Demonstração das conexões inter-camadas.	34
Fig. 7 – Modelo de Perceptron.	35
Fig. 8 – Grafo arquitetural de rede MLP totalmente conectada com duas camadas ocultas.	36
Fig. 9 – Processamento da informação em rede MLP.	37
Fig. 10 – Dados originais de entrada	43
Fig. 11 – Dados originais de saída	44
Fig. 12 – Padrões da NBR5101-2018	44
Fig. 13 – Representação da rede neural para de classificação	45
Fig. 14 – Representação da rede neural para de regressão	46
Fig. 15 – Distribuição dos atributos.	51
Fig. 16 – Gráfico da função de perda ao decorrer de 500 épocas o conjunto de entradas de classificação em MLP.	53
Fig. 17 – Gráfico da função de perda ao decorrer de 500 épocas utilizando o conjunto inteiro em MLP de classificação.	54
Fig. 18 – Gráfico da função de perda ao decorrer de 250 épocas da MLP de regressão.	55
Fig. 19 – Gráfico da função de perda ao decorrer de 250 épocas da MLP de regressão utilizando dados normalizados.	56
Fig. 20 – Gráfico da Função de perda ao decorrer de 250 Épocas da MLP de classifi- cação.	56
Fig. 21 – Curva ROC e área AUC da MLP de classificação.	57

Lista de tabelas

Tab. 1 – Classificação do volume de tráfego.	24
Tab. 2 – Padrões de luminância por classe de iluminação (V).	28
Tab. 3 – Padrões de iluminância por classe de iluminação (V).	28
Tab. 4 – Padrões de iluminância por classe de iluminação (P).	28
Tab. 5 – Sugestão de configurações de malha de acordo com a classe de iluminação da via.	29
Tab. 6 – Matriz de confusão da MLP de classificação.	57

Lista de abreviaturas e siglas

ABNT Associação Brasileira de Normas Técnicas

AM Aprendizado de Máquina

ANEEL Agência Nacional de Energia Elétrica

CNN Redes Neurais Convolucionais

ELM *Extreme Learning Machine*

ESG *Environmental, Social and Governance*

IP Iluminação Pública

LED *Light Emitting Diode*

MLP *Multilayer Perceptron*

NBR Norma Brasileira

PL Projeto Luminotécnico

PPP Parceria Público-Privada

RNAs Redes Neurais Artificiais

RNN Redes Neurais Recorrentes

Lista de símbolos

n	Dimensão do vetor de entradas
E	Iluminância
E_{med}	Iluminância média
E_{min}	Iluminância mínima
$TI\%$	Incremento de Limiar
L	Luminância
L_{max}	Luminância máxima
L_{med}	Luminância média
L_{min}	Luminância mínima
L_V	Luminância de velamento
H	Matriz de saída dos pesos da camada oculta para ELM
β	Matriz pseudo-inversa para ELM
k	Número de rótulos possíveis em uma classificação
SR	Razão das áreas adjacentes à via
η	Taxa de aprendizado
U	Uniformidade da Iluminância
U_0	Uniformidade global da Luminância
U_L	Uniformidade longitudinal da Luminância

Sumário

1	INTRODUÇÃO	19
1.1	Motivação	19
1.2	Objetivos	20
1.2.1	Objetivo geral	20
1.2.2	Objetivos específicos	21
1.3	Estrutura do trabalho	21
2	REVISÃO BIBLIOGRÁFICA	23
2.1	Iluminação pública	23
2.1.1	Vias e suas classificações	23
2.1.2	Especificações de projeto quanto à posição do dispositivo	25
2.1.3	Especificações técnicas dos dispositivos luminosos	26
2.2	Projetos luminotécnicos	27
2.3	Análise do problema	29
2.4	Aprendizado de máquina	30
2.4.1	Classificação	31
2.4.2	Regressão	31
2.5	Redes neurais	32
2.5.1	Aprendizado	32
2.5.2	<i>Perceptron</i>	35
2.5.3	<i>Multilayer Perceptron (MLP)</i>	35
2.5.4	Outras redes neurais	38
2.6	Trabalhos semelhantes	38
3	METODOLOGIA	41
3.1	Ferramentas utilizadas	41
3.2	Análise dos dados e suas influências	41
3.2.1	Inspeção e tratamento da base de dados	46
3.2.2	Normalização e padronização de dados	47
3.3	Construção dos modelos	48
3.3.1	Escolhendo hiper-parâmetros	48
3.3.2	Treinamento, validação e teste	49
3.3.3	Configurações propostas	50
4	RESULTADOS E DISCUSSÕES	51
4.1	Normalização e padronização de dados	51

4.2	Resultados da construção dos modelos	54
4.2.1	MLP de regressão	54
4.2.2	MLP de classificação	56
5	CONCLUSÃO	59
5.1	Conclusões	59
5.2	Sugestões para pesquisas futuras	59
	REFERÊNCIAS	61

1 Introdução

1.1 Motivação

A Iluminação Pública (IP) é o serviço prestado através da elaboração de projetos para iluminar bens e espaços públicos, tais quais: ruas, praças, avenidas, túneis, parques, estradas, passarelas, abrigos de transporte público, monumentos, fachadas e outros (NEOENERGIA, 2021). Seu intuito é proporcionar visibilidade para a segurança do tráfego de veículos e pedestres, de forma rápida, precisa e confortável, principalmente em períodos noturnos ou de visibilidade reduzida (ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 2018).

Uma boa gestão de IP promove também um impacto em sustentabilidade relacionado-se ao meio ambiente, responsabilidade social e governança, (do inglês, *Environmental, Social and Governance* (ESG)), podendo-se evidenciar tópicos como: segurança; mobilidade; cultura; inclusão, preservação de áreas ambientais, reprodução de espécies animais (QLUZ, 2022), bem como redução de acidentes noturnos, melhoria das condições de vida, auxílio à proteção policial para pessoas e propriedades, destaque a edifícios e obras públicas e eficiência energética (ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE ILUMINAÇÃO, 2021a). Tais implicações justificam o esforço do Governo Federal de se garantir a iluminação adequada das diversas áreas urbanas, rurais e industriais através de Parceria Público-Privada (PPP), como forma de acelerar a ampliação e modernização dos parques de IP (MINISTÉRIO DE MINAS E ENERGIA, 2022).

Estimativas mais recentes explicitam que o Brasil possui mais de 18 milhões de pontos de IP espalhados pelo território nacional, representando 4% da energia elétrica consumida no país e correspondendo a 3% a 4% dos orçamentos dos municípios (MEYER et al., 2017). Logo, existe a necessidade de se garantir a implementação da IP em todos os municípios do território nacional, assim como a qualidade da iluminação. O ganho em qualidade (considerando pontos como eficácia, eficiência e efetividade) pode ser acentuado a partir do uso de diversas tecnologias, tanto em equipamentos, como as lâmpadas *Light Emitting Diode* (LED), do inglês, Diodo Emissor de Luz, que consomem menos energia elétrica¹, quanto em fase de projeto (ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE ILUMINAÇÃO, 2015). Estabelece-se que tanto inovações em equipamentos quanto em projeto devem garantir a qualidade de serviço prestado em IP, através do redigido pelas prefeituras, concessionárias de energia, pela Agência Nacional de Energia Elétrica (ANEEL),

¹ Segundo a ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE ILUMINAÇÃO (2015), as lâmpadas LED consomem 85% menos energia que as incandescentes, 65% menos do que as fluorescentes compactas, e 50% menos que as de vapor de sódio

mas, principalmente, pela Associação Brasileira de Normas Técnicas (ABNT), através da Norma Brasileira (NBR) 5101 de 2018, que define padrões a serem seguidos nas implementações de IP na União (ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE ILUMINAÇÃO, 2021a).

Considerando, portanto, a existência de diversas tecnologias e a padronização existente, é possível pensar em abordagens que auxiliem a implementação mais precisa e em menor tempo dos projetos de IP, provendo o acesso a seus benefícios pela população. Existem algumas soluções de mercado, gratuitas e pagas, de *softwares* muito completos e robustos para avaliação e síntese de projetos luminotécnicos, mas pondera-se (considerando haver diversas funcionalidades primárias e secundárias em execução durante elaboração e análise de projetos nestes *softwares*) sobre estes entregarem soluções que avaliem de maneira eficaz, efetiva e eficiente a adequação destes projetos à norma citada.

Propôs-se, portanto, neste trabalho, o uso de técnicas de Aprendizado de Máquina (AM) para identificar se um conjunto de dados de dispositivos e malhas em projetos luminotécnicos está adequado à NBR 5101. Das várias abordagens de AM possíveis de serem exploradas (baseados em distância, probabilidade, procura ou otimização), considerando aspectos como a capacidade de operar grande volume de dados de forma eficiente e a versatilidade na resolução de problemas práticos (FACELI et al., 2011), as Redes Neurais Artificiais (RNAs) (abordagem baseada em otimização) foram escolhidas para este trabalho.

As redes, implementadas com *pytorch* (PYTORCH FOUNDATION, 2023), responderam a duas tarefas, sendo a primeira encontrar os parâmetros de iluminância média e uniformidade da iluminância para a pista de rodagem e passeios adjacente e oposto aos dispositivos luminosos, grandezas que precisam ser medidas em campo (portanto, interessantes de se ter previsibilidade), e a segunda tarefa consiste em, tendo um conjunto de parâmetros de iluminância e uniformidade referidas (utilizando os dados reais, não os preditos), classificar se este atende ou não à NBR 5101. Para obter sucesso neste trabalho, foram estabelecidos testes considerando a acurácia, verdadeiros positivos, verdadeiros negativos (para classificação), erro quadrático médio e r-quadrado (regressão).

1.2 Objetivos

1.2.1 Objetivo geral

Este trabalho tem como objetivo principal encontrar um modelo baseado em redes neurais artificiais do tipo *Multilayer Perceptron* (MLP) *backpropagation* para avaliação de projetos luminotécnicos de IP, visando garantir a conformidade desses projetos com as normas estabelecidas pela NBR 5101.

1.2.2 Objetivos específicos

- Realizar uma revisão detalhada das diretrizes estabelecidas pela [NBR 5101](#), identificando os parâmetros e critérios relevantes para a avaliação de projetos de Iluminação Pública, bem uma revisão acerca de [RNAs MLP](#) no contexto do projeto;
- Analisar os dados utilizados e suas influências sobre as características dos modelos desenvolvidos;
- Construir e avaliar as redes neurais capazes de identificar a conformidade de projetos luminotécnicos com a [NBR 5101](#) e prever os valores de iluminância e uniformidade, utilizando dados simulações de projetos de [IP](#);

1.3 Estrutura do trabalho

Este trabalho está organizado em cinco capítulos. O primeiro tem a função de apresentar a importância do tema em estudo, bem como a motivação deste trabalho, os objetivos e a estrutura geral. O segundo capítulo consiste numa revisão bibliográfica a respeito de iluminação pública, aprendizado de máquina e trabalhos semelhantes de aplicação destas técnicas à área de IP. O terceiro capítulo aborda a metodologia adotada para o estudo e desenvolvimento do modelo. O quarto mostra o processo realizado desde a coleta e transformação sobre os dados até a avaliação dos modelos preditivos, tratando dos resultados obtidos e suas respectivas discussões. O quinto e último capítulo conclui este trabalho, analisando como os objetivos foram tratados e cumpridos e apresenta sugestões de temas para trabalhos futuros relacionados ao tema.

2 Revisão Bibliográfica

Este capítulo trata dos conceitos envolvidos para a realização do projeto. Primeiro, são contextualizados os conceitos e conhecimentos relacionados a **IP**. Em seguida, são analisadas as etapas e ferramentas envolvidas em um Projeto Luminotécnico (**PL**) relacionado a **IP**. Diante desse embasamento teórico, é analisado o problema definido no escopo deste trabalho e são expostas propostas semelhantes na bibliografia, com suas devidas soluções. Após isso, são exploradas as possibilidades que envolvem as soluções em problemas relacionados utilizando **AM**, considerando os dados e os objetivos para os quais são destinados. Por fim, discorre-se sobre **RNAs**, que englobam um conjunto de classes de algoritmos de **AM**, e como estes algoritmos podem ser utilizados para concluir os objetivos do projeto.

2.1 Iluminação pública

IP é relacionada a uma série de conceitos quanto à elaboração de um projeto luminotécnico, definidos através da **NBR 5101** e das devidas normas das prefeituras e concessionárias de energia. Tais conceitos são referentes à especificação técnica das lâmpadas e de suas configurações espaciais no projeto, sendo dimensionados de acordo com as classificações das vias. Assim, é importante contextualizar as classificações e distinções das vias, para, em seguida, conhecer e explicar as variáveis envolvidas no projeto e como estas se conformam nos padrões de qualidade definidos na norma.

2.1.1 Vias e suas classificações

A **ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (2018)** define uma via como uma superfície por onde transitam veículos, pessoas e animais e que compreende a pista, a calçada, o acostamento, ilha e canteiro central. As vias são divididas de acordo com o Código de Trânsito Brasileiro, e, de acordo com a localidade, podem ser vias urbanas e rurais. Destacando-se a primeira categoria, podem ser vias de trânsito rápido, via arterial, coletora ou local (**ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, 2018**). Considerando apenas as vias urbanas, é possível explicitar da seguinte maneira:

- Vias de trânsito rápido são as avenidas e ruas asfaltadas, exclusivas para tráfego de veículos, sem predominância de construções, possuindo acessos especiais com trânsito livre, sem interseções em nível e com velocidade máxima de 80 km/h.

- Vias arteriais também são exclusivas para tráfego de veículos, com várias pistas, cruzamentos em dois planos, escoamento contínuo, e com velocidade máxima em 60 km/h. Possuem interseções em nível (geralmente controladas via semáforo), com acesso às vias secundárias e locais e é proibido o estacionamento na pista.
- Vias coletoras também são exclusivamente para tráfego de veículos, caracterizadas por um volume de tráfego menor e por um acesso de tráfego maior do que as vias arteriais. Coletam e distribuem o trânsito que entra ou sai das vias de trânsito rápido ou arteriais. Sua velocidade máxima é de 40 km/h.
- Vias locais são as que permitem acesso às edificações e a outras vias urbanas. Possuem grande acesso e tráfego leve. Caracteriza-se por interseções em nível sem semáforo e destinam-se apenas ao acesso local ou a áreas restritas. Sua velocidade máxima é de 30 km/h.

A intensidade de tráfego evidenciada para classificar as vias nos itens anteriores pode ser explicada na Tabela 1. Essa dimensão serve para ajudar a delimitar o escopo do projeto quanto às classes de vias (explicadas a seguir) que constituíram o cenário de simulação.

Tab. 1 – Classificação do volume de tráfego.

Classificação	Tráfego de Veículos ²	Tráfego de Pedestres
Sem tráfego	-	Como nas vias arteriais
Leve (L)	150 - 500	Como nas vias residenciais médias
Médio (M)	501 - 1200	Como nas vias comerciais secundárias
Intenso (I)	> 1200	Como nas vias comerciais principais

Fonte: Adaptado de [ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS \(2018\)](#).

Sabendo que, segundo a [ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS \(2018\)](#), os projetos de iluminação pública devem considerar o tipo da via, e seu volume de tráfego (sobre veículos e pedestres), ao definir a classificação de iluminação da via, diferencia-se as destinadas a veículos (V) e aos pedestres (P) da seguinte maneira:

- V1: Vias de trânsito rápido ou vias arteriais, ambas com tráfego intenso.
- V2: Vias de trânsito rápido ou vias arteriais, ambas com tráfego intenso; ou vias coletoras com tráfego intenso.
- V3: Vias coletoras com tráfego médio.
- V4: Vias coletoras com tráfego leve; ou vias locais com tráfego médio.

- V5: Vias locais com tráfego leve.
- P1: Vias de uso noturno intenso por pedestres.
- P2: Vias de grande tráfego noturno de pedestres.
- P3: Vias de uso noturno moderado por pedestres .
- P4: Vias de pouco uso por pedestres.

2.1.2 Especificações de projeto quanto à posição do dispositivo

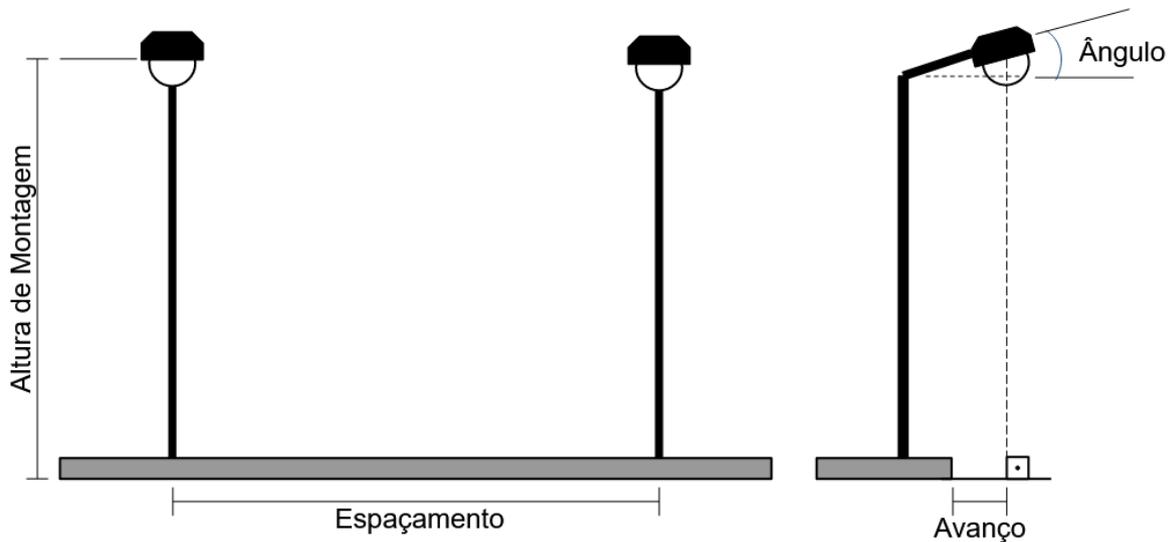
Há vários conceitos a serem explorados na [NBR 5101](#) relativos aos projetos de [IP](#). Por uma questão de foco, foram explicitados apenas os que tiveram relação direta com o desenvolvimento do projeto e que serão apresentados como parâmetros em simulações de projetos luminotécnicos, ilustrados na [Figura 1](#).

- Altura de montagem: Altura em metros do centro de luz da luminária em relação à superfície da rodovia.
- Ângulo dos suportes das luminárias: Ângulo em graus entre o eixo de suporte da luminária e a superfície da via.
- Avanço: Distância em metros entre o meio-fio ou o acostamento e o centro de luz da luminária.
- Espaçamento: Distância em metros entre duas unidades sucessivas de luz.
- Quantidade de faixas: Número de faixas de tráfego que se encontram em uma dada via.
- Razão das áreas adjacentes à via (SR): Relação entre a iluminância média³ das áreas adjacentes à via (com faixa de largura menor ou igual a $5m$) e a iluminância média da via (com faixa de largura menor ou igual a $5m$ ou metade da largura da via) em ambos os lados de suas bordas.

Além destes conceitos, é importante mencionar, como fatores relevantes para o projeto as larguras da pista, do passeio adjacente e do passeio oposto, que influenciam na distribuição de intensidade luminosa necessária para adequação à norma.

³ A ser definida mais adiante

Fig. 1 – Ilustração dos conceitos relativos a posicionamento.



Fonte: Elaborado pelo autor

2.1.3 Especificações técnicas dos dispositivos luminosos

Similarmente aos itens anteriores, foram explicitados apenas os conceitos que tiveram relação direta com o desenvolvimento do projeto.

- Fator de manutenção: Razão adimensional que determina o tempo de vida útil de uma lâmpada. Quanto mais próximo de 1, mais nova a lâmpada e quando menor, mais antiga.
- Fluxo luminoso: Quantidade de luz medida em lumens (lm) emitida por uma fonte luminosa para o espaço iluminado.
- Iluminância (E): Fluxo luminoso que incide sobre um plano, medida em lumens por metros quadrados (lm/m^2), havendo ainda a iluminância média (E_{med}) e a iluminância mínima (E_{min}). Esses são valores calculados a partir da média aritmética das leituras (inspeções) em uma dada configuração espacial (malha), em plano horizontal, sobre o nível do piso e sob as condições estabelecidas, conforme Tabela 5. Os índices consideram os valores mantidos ao longo do tempo de utilização, de acordo com o fator de manutenção.
- Fator de Uniformidade da Iluminância (U): Razão entre a iluminância mínima e média em um plano, $U = E_{min}/E_{med}$. Trivialmente, é uma grandeza adimensional e se considera mais uniforme quão mais próxima a razão for de 1.

- Potência: A quantidade de energia dissipada por uma lâmpada em Watts (W). Importante por impactar na luminância e em outras questões como ofuscamento e temperatura. Alia-se à tecnologia utilizada pela lâmpada (e.g. [LED](#), sódio) para utilização nos projetos devido ao fluxo luminoso inerente a cada tecnologia ([ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE ILUMINAÇÃO, 2021a](#)).

Há ainda, na norma, conceitos que não foram considerados para o projeto, por não fazerem parte do conjunto de dados de simulações obtido para a realização do trabalho, valendo destacar:

- Luminância: Quantidade de luz que atravessa ou é emitida de uma superfície e é refletida em uma dada direção, medida em candela por metro quadrado (cd/m^2). Aparece em seus valores mínimo (L_{min}), médio (L_{med}) e máximo (L_{max}).
- Luminância de velamento (L_V): Efeito provocado pela luz incidente sobre o olho do observador, no plano perpendicular à linha de visão, dependendo do ângulo entre o centro da fonte de ofuscamento e a linha de visão, além da idade do observador.
- Fator da uniformidade global da luminância: Razão entre as luminâncias mínima e média em um plano especificado, $U_0 = L_{min}/L_{med}$.
- Fator da uniformidade longitudinal da luminância: Razão entre as luminâncias mínima e máxima ao longo das linhas paralelas ao eixo longitudinal da via em um plano especificado, $U_L = L_{min}/L_{max}$.
- Índice de ofuscamento: Classificação do desconforto provocado por luminárias, em escala de 1 (insuportável) até 9 (imperceptível).
- Incremento de limiar (TI): Limitação do ofuscamento em vias públicas, que afete visibilidade de objetos. Expressa-se através de $TI\% = 65 \times \frac{L_V}{(L_{med})^{0,8}}$.

2.2 Projetos luminotécnicos

Segundo a [ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE ILUMINAÇÃO \(2021a\)](#), o projeto deve abordar aspectos técnicos do ambiente em que se aplica, suas características de uso, de segurança ao usuário, e de evitar perdas que impactam nos custos de energia, na manutenção dos equipamentos despendidos e que não tragam benefícios necessários aos usuários. Os projetos precisam atender aos padrões da [NBR 5101](#) e a regulações impostas pelas prefeituras das respectivas cidades e distribuidoras responsáveis pela área de concessão.

Considerando os conceitos explicados, é importante apresentar, através deles, como a [NBR 5101](#) estabelece os padrões de adequação. A norma estabelece padrões envolvendo

E , L , U , TI e SR , definindo-os para cada tipo de via V e P. A Tabela 2 explicita os padrões de luminância, bem como incremento de limiar e razão entre áreas das vias para V (não há padrão para vias P). É necessário mencionar que nem todos os dados presentes na referida tabela são padrões, mas recomendações, destacando-se: TI e SR para todos os V e L_{med} , U_0 e U_L para os casos específicos de vias V4 e V5. Logo, requer-se apenas, para vias V1, V2 e V3 L_{med} , U_0 e U_L . Analogamente, os padrões mínimos de E e de U , com relação às classes de vias (para tráfego de veículos e de pedestres), estão expressos nas Tabelas 3 e 4.

Tab. 2 – Padrões de luminância por classe de iluminação (V).

Classe de Iluminação	$L_{med}(cd/m^2)$	$U_0 \geq$	$U_L \geq$	$TI\% \geq$	$SR \geq$
V1	2,00	0,4	0,7	10	0,5
V2	1,50	0,4	0,7	10	0,5
V3	1,00	0,4	0,7	10	0,5
V4	0,75	0,4	0,6	15	0,5
V5	0,50	0,4	0,6	15	0,5

Fonte: Adaptado de ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (2018).

Tab. 3 – Padrões de iluminância por classe de iluminação (V).

Classe de Iluminação	Mínimo $E_{med,min}(lm/m^2)$	Mínimo $U = E_{min}/E_{med}$
V1	30	0,4
V2	20	0,3
V3	15	0,2
V4	10	0,2
V5	5	0,2

Fonte: Adaptado de ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (2018).

Tab. 4 – Padrões de iluminância por classe de iluminação (P).

Classe de Iluminação	Mínimo $E_{med,min}(lm/m^2)$	Mínimo $U = E_{mmi}/E_{med}$
P1	20	0,3
P2	10	0,25
P3	5	0,2
P4	3	0,2

Fonte: Adaptado de ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS (2018).

Faz-se necessário mencionar que há outros pontos de impacto nos projetos luminotécnicos como interferência de galhos em ambientes arborizados e a tonalidade do piso (com cores mais escuras absorvendo mais luz) ([ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE ILUMINAÇÃO, 2021a](#)), mas são muito específicos para as simulações e dependem de outros fatores e serviços para serem alterados que estão fora da elaboração do projeto.

A Tabela 5 apresenta exemplos de configurações de malha, cujas combinações de parâmetros influenciam diretamente nas grandezas medidas que são padronizadas, como E , L e U . Todos os parâmetros podem ser considerados na etapa de elaboração do projeto, realizada através de *softwares* especializados em iluminação, realizando cálculos e simulações visuais. Conforme a [ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE ILUMINAÇÃO \(2021b\)](#) os mais comuns são o Dialux®, o ReluxDesktop® e o AGI32®

Tab. 5 – Sugestão de configurações de malha de acordo com a classe de iluminação da via.

Classe	Vão Médio (m)	Altura de Montagem (m)	Nº de Faixas na Via	Largura de cada Faixa (m)	Largura total da Via (m)	Avanço (m)
V1	40	12	4	3,0	12,0	3,0
V2	35	9	4	2,7	10,8	2,5
V3	35	8	3	3,0	9,0	1,5
V4	35	8	3	3,0	9,0	1,5
V5	35	7	3	2,7	8,1	1,5

Fonte: Adaptado de [ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS \(2018\)](#).

2.3 Análise do problema

A partir do exposto, entende-se que os principais fatores para se determinar se um projeto luminotécnico está dentro dos padrões estabelecidos pela norma para uma determinada malha são E , L e U . Considerando que estes parâmetros são calculados a partir de outras especificações, conforme referenciado previamente, é possível também encontrar valores para E , L e U , para afirmar se um conjunto de especificações de vias e dispositivos luminosos atende ou não à norma. Destaca-se, entretanto, que não foram considerados aspectos de luminância (L) e suas uniformidades neste trabalho devido aos conjuntos de dados simulados obtidos.

Trata-se, portanto, de dois problemas distintos a serem resolvidos: encontrar os E e U de cada malha; e verificar se estes resultados atendem ao especificado pela [ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS \(2018\)](#).

2.4 Aprendizado de máquina

Os dois problemas apresentados para o contexto do projeto são predições, e precisam acertar os valores a partir de várias configurações de malhas, que podem variar muito os respectivos parâmetros. Segundo [Faceli et al. \(2011\)](#), escrever programas para resolver a problemas de predições complexas de resultados que podem ocorrer em diversas aplicações implica em uma dificuldade associada. Ainda conforme [Faceli et al. \(2011\)](#), essa dificuldade pode ser superada ao se aplicar técnicas de [AM](#) para resolver tais problemas.

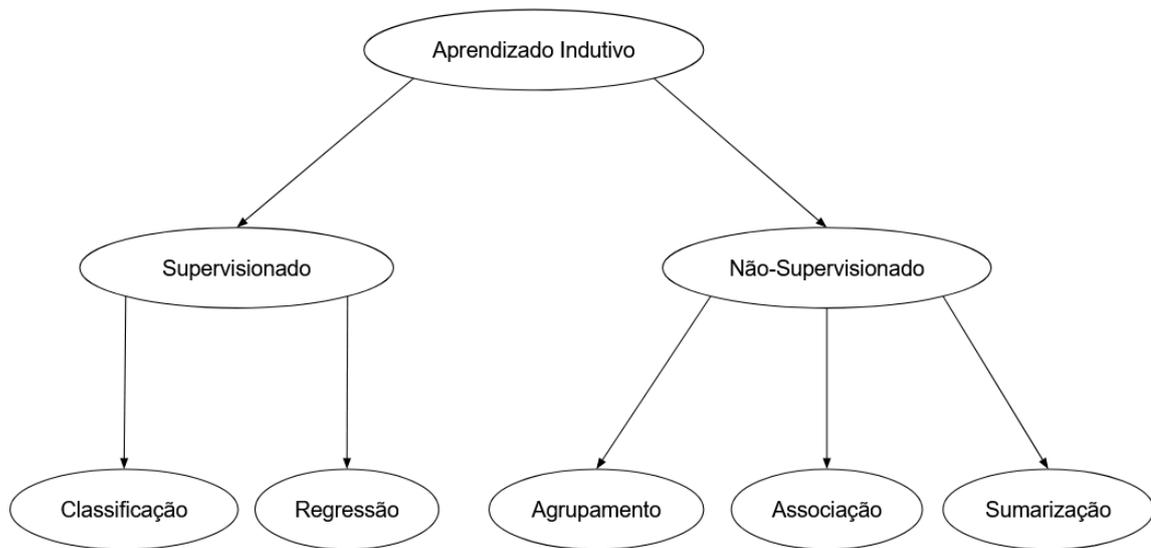
Esta área do conhecimento tem ganhado muito destaque nas últimas décadas, devido à evolução de capacidade do *hardware* de processamento, do exponencialmente crescente volume de dados sobre os mais variados assuntos e à própria evolução de pesquisas relacionadas aos algoritmos ([GOODFELLOW; BENGIO; COURVILLE, 2016](#)). Algumas das aplicações são detecção de câncer de mama através de imagens ([NAHID; MEHRABI; KONG, 2018](#)), e síntese de textos e imagens a partir de processamento de linguagem natural ([OPENAI, 2023](#)).

[Faceli et al. \(2011\)](#) e [Goodfellow, Bengio e Courville \(2016\)](#) apresentam [AM](#) como uma abordagem oposta aos sistemas especialistas ou sistemas baseados em conhecimento, que reúnem o máximo de informações sobre um dado assunto via curadoria de especialistas humanos, para auxiliarem em tomadas de decisões (e.g. *iBM Deep Blue*⁴). Assim, essas técnicas são “capazes de criar por si próprias a partir da experiência passada, uma hipótese, ou função, capaz de resolver o problema que se deseja tratar” ([FACELI et al., 2011](#)). Dentro desta abordagem, há dois objetivos de técnica: preditiva (utiliza-se um conjunto de dados de entrada, com a saída desejada já conhecida, o que serve para avaliar a capacidade do modelo de prever um valor de saída para novos exemplos) e descritiva (Explorar um conjunto de dados desconhecido para relacionar estes dados), sendo respectivamente chamados de aprendizados supervisionado ou não-supervisionado ([FACELI et al., 2011](#)). Verifica-se na [Figura 2](#) as distinções entre os tipos de [AM](#).

É possível, portanto, utilizar das [RNAs](#) para resolver os problemas, definindo um ou mais modelos (funções encontradas a partir de um conjunto de dados, para prever os resultados), seguindo a abordagem de aprendizado supervisionado, pois existem conjuntos de dados de projetos luminotécnicos com as configurações das malhas e saídas desejadas e de atendimento ao padrão exposto na [NBR 5101](#). Os dois problemas identificados para este trabalho se encaixam nas duas categorias de aprendizado supervisionado apresentadas na [Figura 2](#): classificação e regressão.

⁴ Computador projetado para vencer o melhor jogador de xadrez à época, Gasparov, tendo cumprido seu objetivo vencendo-o diretamente ([GOODFELLOW; BENGIO; COURVILLE, 2016](#))

Fig. 2 – Hierarquia de aprendizado.



Fonte: Adaptado de [Faceli et al. \(2011\)](#)

2.4.1 Classificação

Neste tipo de problema, [Goodfellow, Bengio e Courville \(2016\)](#) descrevem como necessidade atribuir a uma combinação de entradas uma categoria possível entre k categorias, estabelecendo uma fronteira de distinção entre diferentes classes e produzindo uma função $f : R^n \rightarrow 1, \dots, k$, resultando em um conjunto discreto e não ordenado de valores, tratados por [Faceli et al. \(2011\)](#) como títulos ou rótulos, sendo n a dimensão do vetor de entradas. Pode-se, portanto, atribuir esta natureza ao problema de decidir se uma configuração de fatores E e U caracteriza um projeto como atendente, ou não, à [NBR 5101](#).

2.4.2 Regressão

[Goodfellow, Bengio e Courville \(2016\)](#) definem os problemas de regressão como aqueles em que se solicita prever um valor numérico a partir de alguma entrada, gerando uma função $f : R^n \rightarrow R$, portanto, um conjunto infinito e ordenado de valores, tratado por [Faceli et al. \(2011\)](#) como escala. Logo, pode-se atribuir essa natureza ao problema de se encontrar os fatores E e U a partir dos n parâmetros de configuração da malha e do dispositivo luminoso utilizado.

2.5 Redes neurais

As **RNAs** constituem uma classe de algoritmos de aprendizado que se inspiram no funcionamento biológico do sistema nervoso humano, consistindo em uma rede de neurônios interligados, propagando informações (GOODFELLOW; BENGIO; COURVILLE, 2016). Segundo Faceli et al. (2011), as **RNAs** são uma classe de algoritmos de otimização de funções, cujo intento é maximizar ou minimizar uma função objetivo, sendo o mais comum, em casos de aprendizado supervisionado, a minimização de uma função de erro.

McCulloch e Pitts (1943) definiram a implementação de um neurônio computacional linear, com entradas, saída e processamento de limiar (função de ativação, detalhada a seguir), em que somam-se as entradas ($X = [x_1, x_2, \dots, x_n]$) de maneira ponderada ($W = [w_1, w_2, \dots, w_n]$), vista na Equação 2.1, realizando a comparação com o limiar e resultando em um classificador de saídas. O peso atribuído a cada entrada é tão maior quanto a importância da respectiva entrada. Também, mostraram que elevaria-se o poder computacional para resolução de problemas de funções lógicas ao combinar estes neurônios, sem propor entretanto, a capacidade de aprendizado, comentada mais à frente.

$$f(x, w) = \sum_{i=0}^n x_i w_i \quad (2.1)$$

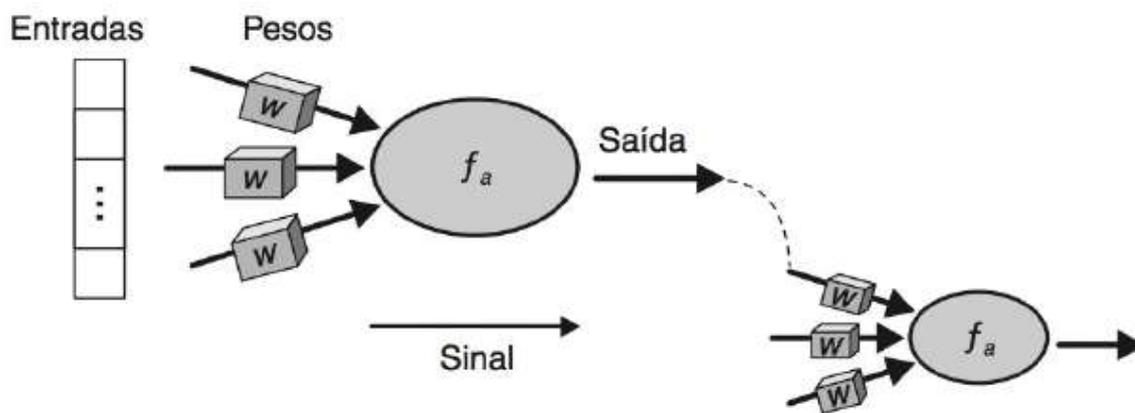
2.5.1 Aprendizado

Conforme Faceli et al. (2011), **RNAs** utilizam-se de neurônios interconectados em camadas (quanto mais camadas, maior a profundidade da rede, sendo a razão pela qual este campo de conhecimento é denominado aprendizado profundo, ou *deep learning*), com a saída de um neurônio sendo o resultado de uma função de ativação (detalhada a seguir) sobre uma soma ponderada de entradas pelos seus respectivos pesos, como representado na Figura 3. Para entender o aprendizado em uma rede neural, é necessário entender como cada neurônio processa e repassa a informação e o que resulta dessa propagação.

As funções de ativação cumprem um papel importante, sendo responsáveis por restringir a amplitude das saídas, gerando implicações distintas no resultado do neurônio. Há várias funções distintas utilizadas para esse fim, como as funções linear, degrau (ou limiar), sigmoideal, (as três apresentadas na Figura 4), ReLU (apresentada na Figura 5) e outras como a tangente hiperbólica e softmax (ML GLOSSARY, 2017). Suas utilizações dependem dos problemas aos quais atendem e dos resultados esperados (por exemplo, é desejável utilizar uma função de saída limitada entre -1 e 1 ou entre 0 e 1 para problemas de classificação binária).

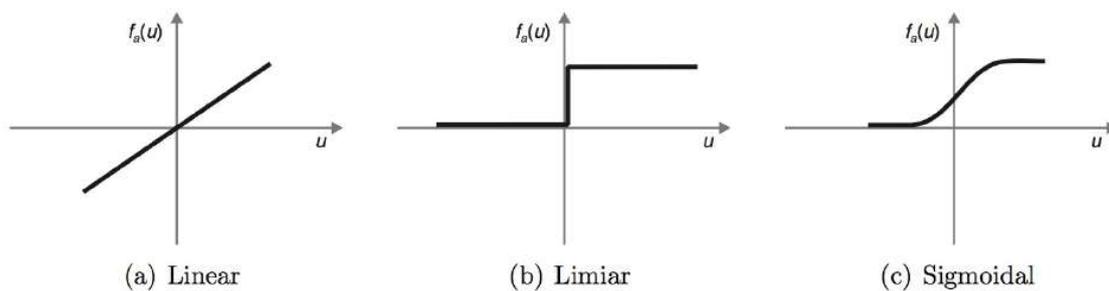
Sabendo-se que **RNAs** podem conter uma ou mais camadas interconectadas, Faceli et al. (2011) definem três possibilidades de conexão entre neurônios considerando suas camadas:

Fig. 3 – Demonstração da conexão entre neurônios de diferentes camadas.



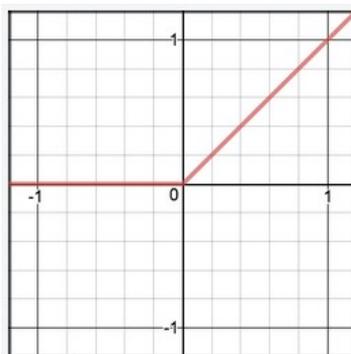
Fonte: Faceli et al. (2011)

Fig. 4 – Exemplos de funções de ativação.



Fonte: Faceli et al. (2011)

Fig. 5 – Exemplo de função de Ativação ReLU.

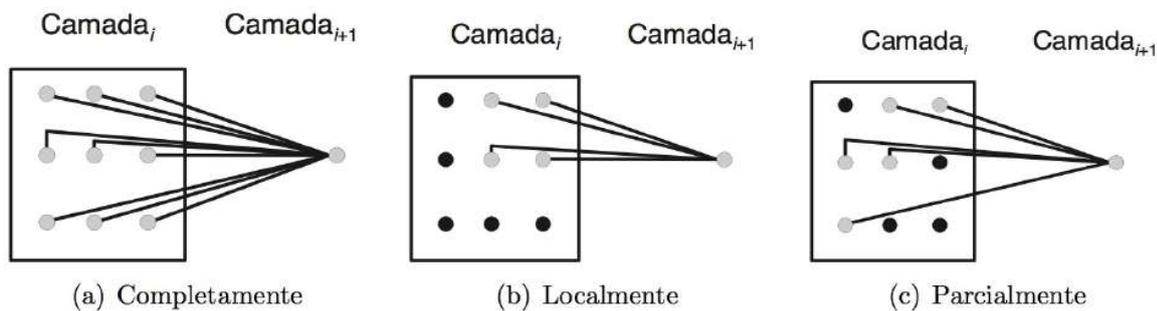


Fonte: ML GLOSSARY (2017)

- Totalmente conectadas: Todos os neurônios de uma camada têm suas saídas conectadas a todos os neurônios da próxima camada;
- Parcialmente conectadas: Quando os neurônios estão conectados a alguns das camadas anteriores ou posteriores;
- Localmente conectadas: Quando os neurônios recebem suas entradas das saídas de neurônios bem localizados na camada anterior.

O sentido da informação pode ser único, propagando as saídas de uma camada para as entradas de outra mais posterior (*feedforward*), ou possibilitar retroalimentação, com um neurônio podendo receber na sua entrada a saída de um outro pertencente a uma camada mais posterior ou de si mesmo (*feedback*) (FACELI et al., 2011). Esta última possibilidade não é explorada neste trabalho, concentrando-se apenas em redes *feedforward*.

Fig. 6 – Demonstração das conexões inter-camadas.



Fonte: Faceli et al. (2011)

Aliados aos modelos de arquiteturas de redes neurais, ou seja, como os *perceptrons* se conectam e propagam informação, o aprendizado da rede precisa existir para haja a mudança na função objetivo. Utiliza-se portanto algoritmos para, a partir dos valores da camada de saída, ajustar os pesos dos neurônios e com isso, obter melhores resultados, definindo o conceito do aprendizado nas redes neurais (FACELI et al., 2011). Existem diversos algoritmos possíveis de serem utilizados, mas Faceli et al. (2011) destaca os algoritmos de correção de erro ⁵ como os mais frequentemente utilizados em situações de aprendizado supervisionado. O aprendizado pode ser medido sob a denominada taxa de aprendizado (η), de forma que a mudança do módulo dos pesos é diretamente proporcional a essa taxa (GOODFELLOW; BENGIO; COURVILLE, 2016).

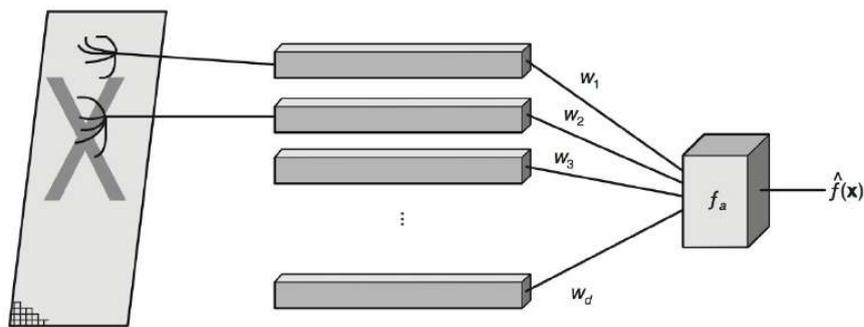
⁵ Conhecendo-se a resultado esperado, os pesos são ajustados para reduzir a diferença entre este e a saída da rede.

2.5.2 Perceptron

Rosenblatt (1958) adapta o modelo descrito por McCulloch e Pitts (1943) e define o *perceptron*, vide Figura 7, com capacidade de aprendizado e utilizando a função de limiar, sendo utilizado principalmente com o objetivo de classificação, conforme Equação 2.2. Devido ao fato de conter uma única camada, com um único neurônio, não possui muito poder de processamento, sendo restrito a modelos linearmente separáveis⁶, o *perceptron*. Apesar desta característica, por implementar o neurônio de (MCCULLOCH; PITTS, 1943), o *perceptron* se torna a unidade básica dos trabalhos futuros de RNAs.

$$y = \phi\left(\sum_{i=0}^n x_i w_i + b\right) \quad (2.2)$$

Fig. 7 – Modelo de Perceptron.



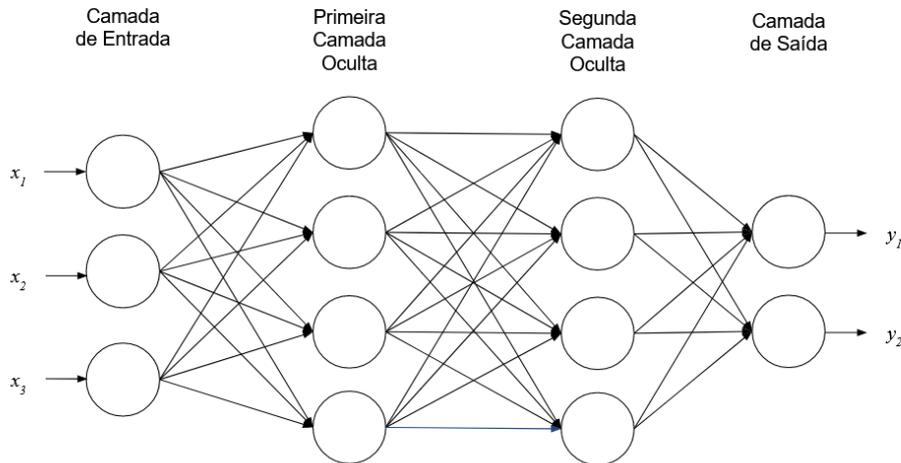
Fonte: Faceli et al. (2011)

2.5.3 Multilayer Perceptron (MLP)

Após o avanço tecnológico de *hardware* nas décadas de 70 e 80 (FACELI et al., 2011; GOODFELLOW; BENGIO; COURVILLE, 2016) e de novas arquiteturas de redes, Rumelhart, Hinton e Williams (1986), no movimento que Goodfellow, Bengio e Courville (2016) nomeiam como “conexionismo”, resgatam as pesquisas acerca de RNAs ao utilizarem o modelo do *perceptron* em camadas interconectadas. A Figura 8 exemplifica a proposta de (RUMELHART; HINTON; WILLIAMS, 1986), trazendo a organização dos perceptrons em camadas totalmente conectadas, com as entradas, saídas e pelo menos uma camada oculta (ou intermediária), demonstrando o conceito do modelo MLP (do inglês, perceptron multicamadas).

⁶ Minsky e Papert (1969) provam a limitação do Perceptron no problema da porta XOR, que, por ser impossível de se traçar uma única reta que separe as classes do problema, é evidenciada a ineficácia do modelo para os problemas não-lineares, deixando os estudos em redes neurais sob suspensão por mais de 15 anos (GOODFELLOW; BENGIO; COURVILLE, 2016). Faceli et al. (2011) generaliza que, para um conjunto de objetos de d -atributos logo, em um espaço de soluções d -dimensional, o perceptron só funciona se a fronteira de decisão for um hiperplano de dimensão $d - 1$.

Fig. 8 – Grafo arquitetural de rede MLP totalmente conectado com duas camadas ocultas.



Fonte: Adaptado de [Goodfellow, Bengio e Courville \(2016\)](#)

A importância do trabalho de [Rumelhart, Hinton e Williams \(1986\)](#) reside principalmente no algoritmo de treinamento *backpropagation*, que possibilitou diversos trabalhos em redes neurais multi-camadas ([GOODFELLOW; BENGIO; COURVILLE, 2016](#)). O algoritmo consiste em duas etapas: *forward* (em que a informação passa das entradas às saídas da rede), que, ao seu findar, implica em uma comparação entre os valores obtidos das saídas dos neurônios da camada de saída e o valor esperado/desejado, resultando em erros; e a etapa de *backward*, em que os erros são utilizados para estimar os pesos dos neurônios das camadas mais anteriores, voltando à entrada e repetindo a iteração [Faceli et al. \(2011\)](#). O erro (e) na iteração (i) em um neurônio (j) é a diferença entre as respectivas saídas desejada e atual, conforme a Equação 2.3.

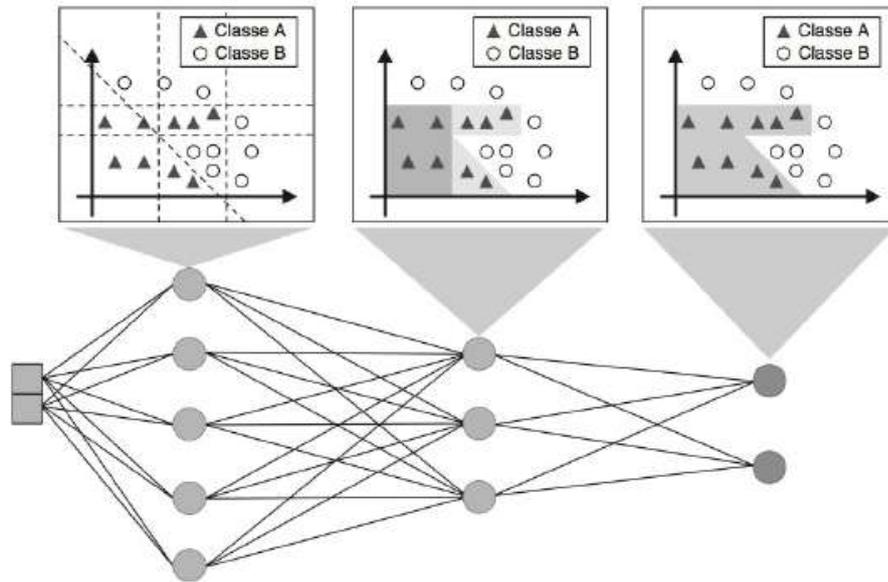
$$e(i,j) = y_{d^j}(i,j) - y_c^j(i,j) \quad (2.3)$$

A parada do algoritmo ocorre se for atingida uma taxa mínima de erro, ou ao atingir um estabelecido número de iterações, ou quando o erro resultante do conjunto de validação começar a aumentar ao decorrer das iterações (conhecido como *early stopping* ([GOODFELLOW; BENGIO; COURVILLE, 2016](#))). Estes pontos são importantes para se conseguir, ao utilizar o *backpropagation* o modelo a ser utilizado ([Faceli et al. \(2011\)](#) e [Goodfellow, Bengio e Courville \(2016\)](#) chamam este processo de treinamento da rede neural), cuja qualidade pode ser medida ao alimentar a mesma rede com novos dados, sem reajustar mais os pesos, portanto, sem aplicar *backward* (o que [Faceli et al. \(2011\)](#) e [Goodfellow, Bengio e Courville \(2016\)](#) nomeiam como teste).

Além da importância dos pesos dos neurônios da rede para o *backpropagation*, que são geralmente iniciados de forma aleatória (FACELI et al., 2011), há a influência de η , de forma que, se for muito baixa, são necessários muitos ciclos para a melhoria do modelo e, se muito alta, cria oscilações que dificultam a convergência.

(FACELI et al., 2011) aborda ainda que redes MLP costumemente apresentam funções de ativação não-lineares nas camadas intermediárias. O fato de cada *perceptron* exercer uma função a partir do resultados dos anteriores é o que proporciona que uma MLP consiga resolver problemas não-linearmente separáveis. A Figura 9 demonstra (em um exemplo de classificação) como, em cada camada, a separação de hiperplanos por cada perceptron constrói uma fronteira de decisão não-linear para separação entre duas classes. A partir do modelo de MLP, Cybenko (1989) concluiu que uma rede neural *feedforward* de pelo menos uma camada oculta com não-linearidade sigmoideal pode aproximar qualquer função contínua, validando assim o funcionamento das redes MLP.

Fig. 9 – Processamento da informação em rede MLP.



Fonte: Faceli et al. (2011)

Necessita-se, entretanto, enunciar que para a convergência do erro a um valor mínimo observável em uma rede multicamadas, não é possível saber se o mínimo encontrado é local ou global (FACELI et al., 2011), podendo ser necessário um treinamento longo para descobrir se há a coincidência. Portanto, lentidão de convergência, excesso de iterações - denominadas a partir de agora com épocas (GOODFELLOW; BENGIO; COURVILLE, 2016) - e ocasiões que exijam redes com muitos neurônios são problemas destacados na literatura para essa classe de RNAs.

2.5.4 Outras redes neurais

Há vários outros modelos de redes neurais e variações, conforme Wang et al. (2022), sendo exemplos as Redes Neurais Recorrentes (RNN) e Redes Neurais Convolucionais (CNN). As primeiras consistem em redes com estrutura de memória, muito utilizadas em problemas de entradas sequenciais (GOODFELLOW; BENGIO; COURVILLE, 2016), enquanto as segundas são estruturadas para reconhecimento de padrões de cores, bordas, formas, muito utilizadas em problemas de reconhecimento de imagem (BENGIO; LECUN, 1997). Exemplos de aplicações costumeiras para estes tipos de redes são reconhecimento de fala e linguagem natural e também reconhecimento de imagens (GOODFELLOW; BENGIO; COURVILLE, 2016). Considerando tais características, optou-se por não implementá-las na resolução dos problemas propostos neste projeto, não oferecendo mais destaques a estas redes.

Há também, considerando as principais características exploradas das redes MLP, as redes *Extreme Learning Machine* (ELM) (HUANG; ZHU; SIEW, 2004). Sua topologia consiste em uma única camada intermediária, com pesos inicializados aleatoriamente, que são ajustados após a primeira iteração, através de uma multiplicação matricial, pela matriz pseudo-inversa (HUANG; ZHU; SIEW, 2006), sendo o próprio algoritmo chamado de ELM. Apesar de Huang, Zhu e Siew (2004) demonstrarem sua rapidez em obter bons resultados, devido à inicialização aleatória de pesos, esta possibilidade não necessariamente oferece os melhores modelos, ou equações de saída, para se aplicar em IP, estando também, as ELMs, fora do escopo deste trabalho.

2.6 Trabalhos semelhantes

Foram encontrados alguns trabalhos relacionados ao uso de RNAs aplicadas ao contexto de iluminação pública que podem ser destacados. No primeiro, Santos e Costa (2023) desenvolvem um modelo de rede neural baseado em ELM para simulação de projetos de iluminação pública, com foco em redução do tempo de simulação, economia de energia e baixa taxa de erros, resultando em um erro menor do que 6% em relação às simulações do DIALux, ao simular 1.000 tipologias de rede diferentes em 10 segundos.

Em outro trabalho, Bakri et al. (2022) utilizam aprendizado profundo aplicado ao contexto de simulação pública, mas para integrar em um controlador que administre o fluxo luminoso emitido pelas lâmpadas de acordo com o horário e detecção de movimento, com foco em eficiência energética sem deixar de prestar um serviço que atenda às necessidades da população, conseguindo 20% de economia de energia com 90% de precisão.

Aplica-se, também, aprendizado profundo no contexto de *hardware* para iluminação pública no trabalho de Lee, Zhang e Rosa (2019), em um modelo de prevenção e diagnóstico de falha de lâmpadas baseado no algoritmo ELM, aumentando em 1% a acurácia, porém

obtendo respostas quase 30% mais rápido do que o modo tradicional.

[Garces-Jimenez et al. \(2019\)](#), por sua vez, aplicam diferentes configurações de [MLP](#), variando o número de camadas intermediárias, o número de neurônios nestas camadas, e o algoritmo de treinamento, para encontrar soluções mais otimizadas em simulações de projetos de iluminação pública, utilizando dados do DIALux para treinamento das redes propostas. Como resultado, identificou-se que a performance aumentou em proporção direta com o número de camadas e o número de neurônios por camada, e os melhores algoritmos de treinamento foram o de Bayes e o Levenberg-Marquardt sendo o segundo dez vezes mais rápido para treinar com 648 amostras em uma rede de seis entradas e duas saídas.

Finalizando os trabalhos semelhantes, há o de [Mohandas, Dhanaraj e Gao \(2019\)](#), que apresentam um sistema de iluminação pública baseado em [RNAs](#) testando diferentes componentes de hardware como sensores de movimento e de luminosidade, reduzindo a utilização desnecessária em 34% e o consumo energético em 13,5%.

Os trabalhos levantados auxiliaram a estabelecer o contexto de Iluminação pública e os aspectos considerados para o projeto, destacando como mais próximos do tema de aplicação de técnicas de [AM](#) no contexto de simulação de projetos de [IP](#), os de [Santos e Costa \(2023\)](#) e [Garces-Jimenez et al. \(2019\)](#). Consequentemente, estes trabalhos serviram como referências da metodologia, a ser abordada no próximo capítulo.

3 Metodologia

O trabalho é uma pesquisa de natureza exploratória quali-quantitativa, que consiste na resolução de dois problemas: Encontrar um modelo preditivo que determine qual a iluminância média e fator de uniformidade que uma malha de projeto de iluminação pública gera a partir de um conjunto de configurações, bem como se estes fatores atendem às especificações descritas na [NBR 5101 de 2018](#). Este capítulo foi baseado nos aspectos práticos a respeito de exploração e avaliação dados e de treinamento e avaliação de [RNAs](#), abordados em [Faceli et al. \(2011\)](#), [Goodfellow, Bengio e Courville \(2016\)](#) e [Huang, Zhu e Siew \(2006\)](#). Como referência para a implementação das redes em ambiente programado, foi utilizada a documentação do *Pytorch* ([PYTORCH FOUNDATION, 2023](#)). Neste capítulo são tratados os passos necessários para cumprir o escopo do projeto.

3.1 Ferramentas utilizadas

O desenvolvimento deste trabalho foi feito na linguagem *Python*, devido a sua versatilidade, comunidade, aplicação em técnicas de [AM \(PYTHON SOFTWARE FOUNDATION, 2023\)](#) e possibilidade de, por ser uma linguagem de programação, possibilitar construir aplicações que utilizem os modelos desenvolvidos. As [RNAs](#) foram implementadas com a ajuda dos pacotes *pytorch* (para construir, treinar e testar), devido ao seu poder de processamento (incluindo a possibilidade de utilizar equipamentos de *hardware* dedicados via ambiente virtualizado ([PYTORCH FOUNDATION, 2023](#)), diferindo-o de outra ferramentas como *keras*) e forma de implementação (que adversa por exemplo do *pycaret*) e o *scikit-learn*, escolhido para se trabalhar com os dados e validações durante o processamento ([SCIKIT-LEARN PROJECT, 2023](#)), além de pacotes disponíveis em [PYTHON SOFTWARE FOUNDATION \(2023\)](#), como *numpy* e *pandas*.

Considerado o exposto em [Faceli et al. \(2011\)](#), [Goodfellow, Bengio e Courville \(2016\)](#) e [Huang, Zhu e Siew \(2006\)](#) a respeito do tempo e complexidade do algoritmo *back-propagation*, que escala em proporção direta com o tamanho do conjunto de dados e da máquina com este treinada, portanto, necessitando de poder computacional, foi escolhido um ambiente de desenvolvimento virtualizado (*Google Colab*) para se implementar o projeto, tentando acelerar os treinamentos das [RNAs](#).

3.2 Análise dos dados e suas influências

Os objetivos descritos para este trabalho, principalmente o primeiro, dependiam de obter um conjunto de dados envolvendo as configurações de malhas, especificações

de dispositivos, E e U citados no Capítulo 2 para simular malhas de IP. Sob esta ótica, preferiu-se utilizar dados reais em detrimento de fictícios (gerados a partir de uma função de distribuição), devido aos valores e escalas utilizados estarem mais relacionados com o contexto real de projetos luminotécnicos. Para tal, foram cedidos conjuntos de parâmetros de simulação de projetos com mais de 250.000 objetos (precisamente, 254.741), por uma empresa prestadora de serviço de IP, a 42lux, tendo sido eliminadas quaisquer informações no conjunto que pudesse identificar equipamentos ou endereços, restando apenas os necessários ao projeto. Considerou-se que para estes dados, todas as lâmpadas são caracterizadas como LED, simplificando o modelo.

Ressalta-se o que conjunto de dados enviado pela empresa não tratava a luminância, descartando-a assim dos fatores implicantes para o atendimento à norma via classificação, bem como impossibilitando ser utilizada como uma possível saída da regressão, uma vez que não há uma saída pronta para se utilizar no treinamento, elemento essencial para aprendizado supervisionado. Portanto, para fins de validação do projeto, a regressão teve somente E e U como saídas e estes, junto à classe da via, foram utilizados na classificação do atendimento à NBR 5101.

As Figuras 10, 11 e 12 trazem recortes sobre os dados na forma exata em arquivo com a qual foram recebidos, ou seja, diretamente da fornecedora, sem intervenções. Ao observar os dados e listar os atributos encontrados nas colunas, é possível listá-los de acordo com as respectivas matrizes¹:

- Planilha nomeada como “Entradas” no conjunto de dados fornecido:

“TIPOLOGIA ORIGINAL”: O atributo define uma configuração espacial de projeto, que envolve boa parte dos itens listados aqui, com exceção da classificação e do fator de manutenção;

“Classificação”: O tipo de via, que aqui conjuga os tipos V e P;

“Largura Passeio Adjacente”;

“Largura Pista 1”: Largura do passeio da pista de rodagem imediatamente após o passeio adjacente;

“Largura Passeio Oposto”;

“Distância Entre postes”;

“Altura”;

“Projeção”;

“Recuo”;

“FATOR DE MANUTENÇÃO”.

¹ Recorda-se que as definições foram exploradas no Capítulo 2, sendo portanto exploradas a seguir as colunas que não estejam tão explícitas

Fig. 10 – Dados originais de entrada

	A	B	C	D	E	F	G	H	I	J
1	TIPOLOGIA ORIGINAL	Classificação	Largura Passeio Adjacente	Largura Pista 1	Largura Passeio Oposto	Distância entre postes	Altura	Projeção	Recuo	FATOR DE MANUTENÇÃO
2	TIPOLOGIA 00001	V4-P3	2,50	9,00	2,50	40,00	8,00	2,35	0,50	0,80
3	TIPOLOGIA 00002	V4-P3	2,50	8,00	2,50	39,00	8,00	2,35	0,50	0,80
4	TIPOLOGIA 00003	V4-P3	2,50	8,00	2,50	36,00	8,00	2,35	0,50	0,80
5	TIPOLOGIA 00004	V4-P3	2,50	6,00	2,50	35,00	8,00	2,35	0,50	0,80
6	TIPOLOGIA 00005	V4-P3	2,50	10,00	2,50	35,00	8,00	2,35	0,50	0,80
7	TIPOLOGIA 00006	V4-P3	2,50	8,00	2,50	38,00	8,00	2,35	0,50	0,80
8	TIPOLOGIA 00007	V4-P3	2,50	8,00	2,50	35,00	8,00	2,35	0,50	0,80
9	TIPOLOGIA 00008	V4-P3	2,50	7,50	2,50	35,00	8,00	2,35	0,50	0,80
10	TIPOLOGIA 00009	V4-P3	2,50	9,00	2,50	38,00	8,00	2,35	0,50	0,80
11	TIPOLOGIA 00010	V4-P3	2,50	8,00	2,50	42,00	8,00	2,35	0,50	0,80
12	TIPOLOGIA 00011	V4-P3	2,50	8,00	2,50	40,00	8,00	2,35	0,50	0,80
13	TIPOLOGIA 00012	V4-P3	2,50	8,00	2,50	34,00	8,00	2,35	0,50	0,80
14	TIPOLOGIA 00013	V4-P3	2,50	7,50	2,50	36,00	8,00	2,35	0,50	0,80
15	TIPOLOGIA 00014	V4-P3	2,50	8,00	2,50	33,00	8,00	2,35	0,50	0,80
16	TIPOLOGIA 00015	V4-P3	2,50	7,00	2,50	35,00	8,00	2,35	0,50	0,80
17	TIPOLOGIA 00016	V4-P3	2,50	7,50	2,50	44,00	8,00	2,35	0,20	0,80
18	TIPOLOGIA 00017	V4-P3	2,50	7,50	2,50	40,00	8,00	2,35	0,50	0,80
19	TIPOLOGIA 00018	V4-P3	1,00	5,40	1,00	35,00	8,00	2,35	0,50	0,80
20	TIPOLOGIA 00019	V4-P3	2,50	8,00	2,50	46,00	8,00	2,35	0,50	0,80
21	TIPOLOGIA 00020	V4-P3	2,50	8,00	2,50	41,00	8,00	2,35	0,50	0,80
22	TIPOLOGIA 00021	V4-P3	2,50	8,00	2,50	35,00	8,00	2,35	3,00	0,80
23	TIPOLOGIA 00022	V4-P3	2,50	7,50	2,50	44,00	8,00	2,35	1,00	0,80
24	TIPOLOGIA 00023	V4-P3	2,50	7,50	2,50	43,00	8,00	2,35	1,00	0,80
25	TIPOLOGIA 00024	V4-P3	2,50	7,50	2,50	40,00	8,00	2,35	3,60	0,80
26	TIPOLOGIA 00025	V4-P3	2,50	10,00	2,50	42,00	8,00	2,35	0,50	0,80
27	TIPOLOGIA 00026	V4-P3	2,50	10,00	2,50	30,00	8,00	2,35	0,50	0,80
28	TIPOLOGIA 00027	V4-P3	2,50	7,50	2,50	45,00	8,00	2,35	0,50	0,80
29	TIPOLOGIA 00028	V4-P3	2,50	7,50	2,50	39,00	8,00	2,35	0,50	0,80
30	TIPOLOGIA 00029	V4-P3	2,50	7,50	2,50	33,00	8,00	2,35	0,50	0,80
31	TIPOLOGIA 00030	V4-P3	2,50	6,00	2,50	33,00	8,00	2,35	1,00	0,80
32	TIPOLOGIA 00031	V4-P3	2,50	8,00	2,50	40,00	8,00	2,35	0,40	0,80
33	TIPOLOGIA 00032	V4-P3	2,50	7,00	2,50	44,00	8,00	2,35	0,50	0,80
34	<									

Fonte: Concessão por parte da 42lux.

- Planilha nomeada como “Saídas” no conjunto de dados fornecido:

“TIPOLOGIA”: Complementa-se à coluna homônima na planilha de entradas que, nesta planilha de saídas, há uma repetição de tipologias nomeadas, variando-se os valores de potência e ângulo para se obter diversos valores de E_s e U_s ;

“POTÊNCIA”;

“ÂNGULO”;

“NBR5101 - 2018”: Coluna que explicita se, no conjunto de dados avaliado pela empresa, os parâmetros observados estão adequados ou não à referida norma, que nomeia a coluna;

“ $E_m(lx)$ - Passeio 1”: Iluminância no passeio adjacente à via;

“ U_0 - Passeio 1”;

“ $E_m(lx)$ - Pista de Rodagem 1”: Iluminância na pista imediatamente após o passeio 1;

“ U_0 - Pista de Rodagem 1”;

“ $E_m(lx)$ - Passeio 2”: Iluminância no passeio oposto à via;

“ U_0 - Passeio 2”.

Fig. 11 – Dados originais de saída

	A	B	C	D	E	F	G	H	I	J
1	TIPOLOGIA	POTÊNCIA	ÂNGULO	NBR5101-2018	E_m (lx) - Passeio 1	U_o - Passeio 1	E_m (lx) - Pista de rodagem 1	U_o - Pista de rodagem 1	E_m (lx) - Passeio 2	U_o - Passeio 2
2	TIPOLOGIA 00001	50	15,00	OK	5,17	0,34	11,20	0,33	7,58	0,70
3	TIPOLOGIA 00001	60	15,00	OK	6,12	0,27	13,46	0,30	9,26	0,74
4	TIPOLOGIA 00001	70	15,00	OK	6,59	0,32	15,12	0,33	10,42	0,70
5	TIPOLOGIA 00001	80	15,00	OK	8,06	0,36	17,42	0,34	11,66	0,68
6	TIPOLOGIA 00001	100	15,00	OK	9,46	0,33	20,49	0,32	13,88	0,70
7	TIPOLOGIA 00001	120	15,00	OK	9,56	0,20	24,06	0,23	15,61	0,70
8	TIPOLOGIA 00001	20	15,00	NÃO ATENDE	2,26	0,30	5,00	0,32	3,42	0,72
9	TIPOLOGIA 00001	30	15,00	NÃO ATENDE	2,90	0,20	7,05	0,26	4,70	0,71
10	TIPOLOGIA 00001	40	15,00	NÃO ATENDE	4,11	0,27	9,04	0,30	6,22	0,74
11	TIPOLOGIA 00001	100	15,00	NÃO ATENDE	11,02	0,17	16,68	0,21	12,56	0,52
12	TIPOLOGIA 00001	50	-	OK	8,72	0,49	12,43	0,40	5,63	0,74
13	TIPOLOGIA 00001	50	5,00	OK	7,62	0,48	12,18	0,38	6,48	0,67
14	TIPOLOGIA 00001	50	10,00	OK	6,43	0,44	11,76	0,36	7,20	0,67
15	TIPOLOGIA 00001	60	-	OK	10,45	0,47	15,03	0,39	6,98	0,76
16	TIPOLOGIA 00001	60	5,00	OK	9,10	0,45	14,69	0,38	8,05	0,71
17	TIPOLOGIA 00001	60	10,00	OK	7,64	0,39	14,15	0,35	8,86	0,71
18	TIPOLOGIA 00001	70	-	OK	11,57	0,50	16,94	0,40	7,99	0,71
19	TIPOLOGIA 00001	70	5,00	OK	10,01	0,49	16,54	0,38	9,07	0,67
20	TIPOLOGIA 00001	70	10,00	OK	8,34	0,44	15,92	0,37	9,96	0,67
21	TIPOLOGIA 00001	80	-	OK	13,60	0,48	19,24	0,39	8,49	0,73
22	TIPOLOGIA 00001	80	5,00	OK	11,89	0,49	18,90	0,38	9,84	0,67
23	TIPOLOGIA 00001	80	10,00	OK	10,05	0,45	18,27	0,36	10,97	0,65
24	TIPOLOGIA 00001	100	-	OK	16,00	0,47	22,74	0,39	10,35	0,75
25	TIPOLOGIA 00001	100	5,00	OK	13,97	0,46	22,28	0,37	11,96	0,69
26	TIPOLOGIA 00001	100	-	OK	13,86	0,32	19,09	0,31	11,08	0,50
27	TIPOLOGIA 00001	100	5,00	OK	12,98	0,28	18,36	0,28	12,29	0,51
28	TIPOLOGIA 00001	100	10,00	OK	12,04	0,23	17,53	0,25	12,72	0,52
29	TIPOLOGIA 00001	100	10,00	OK	11,77	0,42	21,50	0,35	13,18	0,68
30	TIPOLOGIA 00001	120	-	OK	17,95	0,41	26,47	0,34	9,10	0,68
31	TIPOLOGIA 00001	120	5,00	OK	15,26	0,37	26,10	0,34	12,27	0,66

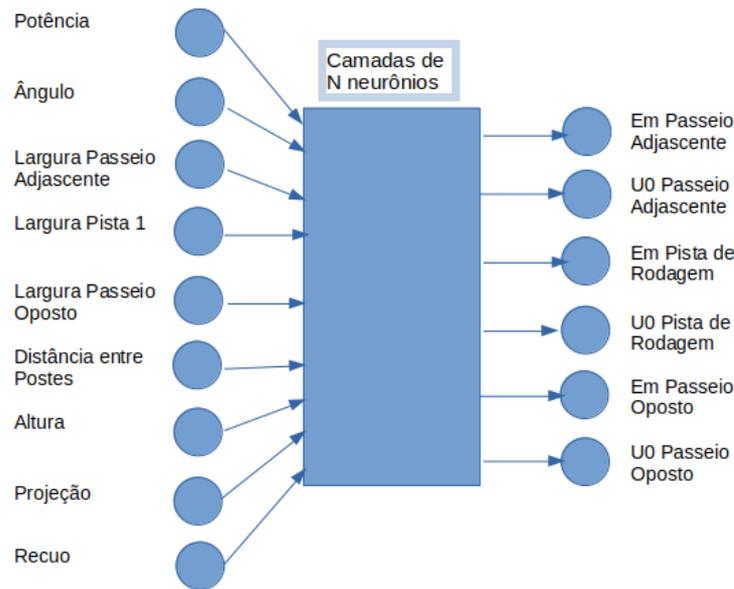
Fonte: Concessão por parte da 42lux.

Fig. 12 – Padrões da NBR5101-2018

	A	B	C	D	E	F
1	PARÂMENTOS NBR 5101 - 2018					
2						
3	V1	30,00	2,00	0,40	0,40	0,70
4	V2	20,00	1,50	0,30	0,40	0,70
5	V3	15,00	1,00	0,20	0,40	0,70
6	V4	10,00	0,75	0,20	0,40	0,60
7	V5	5,00	0,50	0,20	0,40	0,60
8						
9						
10	P1	20	0,3			
11	P2	10	0,25			
12	P3	5	0,2			
13	P4	3	0,2			
14						

Fonte: Concessão por parte da 42lux.

Fig. 13 – Representação da rede neural para de classificação



Fonte: Elaborado pelo autor

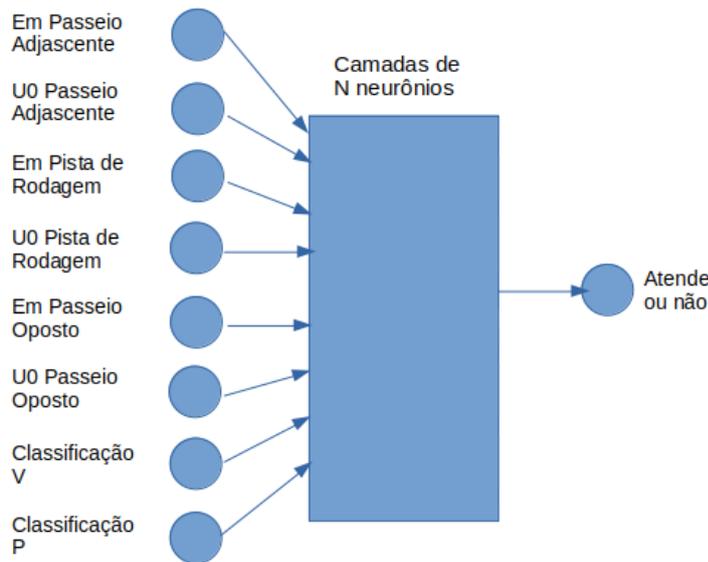
Discorre-se, sobre a Figura 12, que é apresentado apenas um resumo sobre os padrões estabelecidos na NBR 5101. Conforme mencionado, a figura retrata os arquivos na forma recebida diretamente pela fornecedora, o que explica a ilegibilidade dos nomes. Destaca-se que, apesar deste fato, a planilha não é necessária para a alimentação do modelo, visto que as redes implementadas aprendem com o treinamento dos dados ao entender o e criar o próprio conceito sobre quais devem ser os valores dos parâmetros de entrada para que seja declarada a adequação.

Considerando a natureza dos dois problemas a serem tratados, entende-se desde já que não são necessárias todas as entradas para solucionar os problemas de regressão e de classificação. Dessa forma, foi necessário, após realizar ajustes (detalhados a seguir), criar dois novos conjuntos de dados, um para cada problema, utilizando os dados após tratamento, a ser detalhado a seguir.

As Figuras 13 e 14 demonstram quais entradas e saídas importam para os modelos respectivos de regressão e de classificação (com, nesta ordem, nove entradas e seis saídas e oito entradas e uma saída), através de uma representação que adota, para o exemplo, uma generalização da quantidade de camadas ocultas e seus respectivos neurônios. Essas representações ajudam a ilustrar como foram montadas as redes após todo o tratamento de dados, descrito a seguir.

Apesar de haver uma repetição de colunas entre as duas representações de redes, é importante mencionar que ambas as redes estão desconexas, não havendo propagação da informação da regressão à classificação. Tal escolha segue as bases do aprendizado

Fig. 14 – Representação da rede neural para de regressão



Fonte: Elaborado pelo autor.

supervisionado, de se utilizar os dados conhecidos de entrada e saída para prever saídas generalizadas.

3.2.1 Inspeção e tratamento da base de dados

Acessados os dados, foi necessário realizar algumas transformações, conforme orienta [Faceli et al. \(2011\)](#), para garantir que pudessem ser utilizados no desenvolvimento dos modelos.

Considerando que as entradas e saídas de ambos os modelos se encontravam em matrizes diferentes, o que dificultaria o tratamento (seria necessário realizar operações repetidas e porque seria necessário garantir que quaisquer transformações realizadas não afetassem a relação de implicação entre as entradas e as saídas devidas dos modelos), foi mandatário realizar uma integração dos dados (Dados em diferentes conjuntos que representam diferentes atributos de um mesmo objeto ([FACELI et al., 2011](#))).

A listagem das colunas evidencia que, apesar de muito diferentes, as matrizes de dados tinham a coluna Tipologia em comum, e, conforme as Figuras 10 e 11, para cada tipologia na matriz de entrada, há várias linhas com combinações diferentes na matriz de saídas, configurando a coluna como a chave de relacionamento entre as duas matrizes e possibilitando a análise em uma única matriz.

Ao combinar as matrizes de entrada e saída em uma única matriz, as 6.368 linhas de entrada (topologias distintas) se ajustaram com as 254.741 linhas de saída, resultando

em uma matriz 254.741x19 (254.741 objetos, possuindo 19 atributos). Há outros tantos ajustes que foram realizados, podendo-se enumerar:

- Renomear as colunas para nomes mais simples e adequados ao entendimento dos dados;
- Limpeza de dados: Eliminar objetos em que há ocorrência de erros nos atributos, o que evita de propagá-los nos modelos a serem treinados. Aproximadamente 25% dos valores da coluna “Ângulo” eram “-”, e as colunas “Distância entre Postes” e “Recuo” continham erros (“nan”, que indica tipos de dados não numéricos). Neste caso foi tratado o ângulo como 0° (indicações da fornecedora) e os objetos com erros “nan” foram removidos do conjunto (indicação da fornecedora a respeito de erros de projeto).;
- Eliminação de redundância de dados: Dados redundantes são aqueles que podem ser obtidos através de outros dados, sendo portanto desnecessários aos modelos e economizando processamento em sua retirada. Denota-se essa característica na remoção das colunas “Fator de Manutenção” e “Tipologia” (a primeira possuía um único valor, e a segunda indicava apenas uma combinação de fatores relacionados ao posicionamento da lâmpada);
- Conversão numérico-simbólico: Tratamento de atributos nominais para utilizar como números operáveis. Além de converter os dados numéricos, que estavam como *strings*, foi feita a conversão dos dados que caracterizavam o atendimento ou não à norma na coluna “NBR5101-2018” para 1 ou 0 (atende ou não atende), bem como, após separar a coluna de classificação para duas colunas com as classificações V e P, como havia apenas dois valores de cada tipo de via, houve a conversão para valores 1 e 0;
- Transformação de atributos numéricos: Aplicação de normalização/padronização dos dados para atenuar os pesos atribuídos às entradas conforme a escala são definidos três tipos em [Faceli et al. \(2011\)](#): normalização por intervalo, normalização por valor máximo e padronização. Este ponto é melhor explorado a seguir.

Finalizou-se a análise separando os conjuntos de entrada e saída adequados para cada problema, de forma que a rede de regressão passou a ter nove neurônios na camada de entrada e seis na camada de saída, enquanto a rede de classificação passou a ter oito neurônios na camada de entrada e uma na de saída, conforme observado nas Figuras 13 e 14.

3.2.2 Normalização e padronização de dados

Para analisar a influência dos dados no comportamento das máquinas, ([FACELI et al., 2011](#)) recomenda algumas visualizações, tendo sido escolhida a de *boxplots*, por

permitir visualizar os intervalos e as distribuições de cada atributo para o conjunto de objetos.

Considerando a recomendação dos autores a respeito de normalização/padronização, foi necessário entender qual forma de dados seria mais adequada para se trabalhar o conjunto de dados, justificando a construção de uma rede de classificação *feedforward* com *backpropagation* específica, apenas para verificar os diferentes gráficos de perda por época dos treinamentos. Para realizar as transformações do conjunto de dados, foi utilizado o módulo *preprocessing* do [SCIKIT-LEARN PROJECT \(2023\)](#), que contém as classes *MinMaxScaler*, *MaxAbsScaler* e *StandardScaler*.

Aplicando as técnicas de normalização e padronização sob o conjunto de dados para classificação, conforme a Figura 14, a melhor estratégia foi escolhida mediante análise curva da função de perda ([FACELI et al., 2011](#)), referente à etapa de treinamento.

3.3 Construção dos modelos

Ao entender as capacidades dos modelos *feedforward* com os algoritmos *backpropagation*, foi proposta a construção de dois tipos de topologias de RNAs (por necessidade de projeto, mais máquinas foram necessárias por cada tipo), aplicando o algoritmo para regressão e para o problema de classificação.

A construção dos modelos foi baseada nas especificações de aspectos práticos de treinamento por [Faceli et al. \(2011\)](#), utilizando as funções específicas do [PYTORCH FOUNDATION \(2023\)](#) no módulo *nn* e na classe *nn.Module*, para implementar uma classe para cada topologia, respeitando os tamanhos das camadas de entradas e saídas, e métodos para fazer o *feedforward*, o treino e o teste, bem como as devidas funções de ativação, otimização, critério para a função de perda ([FACELI et al., 2011](#)).

3.3.1 Escolhendo hiper-parâmetros

Hiper-parâmetros são variáveis que influenciam no modelo, definidos manualmente e ajustáveis conforme a necessidade do modelo ([GOODFELLOW; BENGIO; COURVILLE, 2016](#)). [Faceli et al. \(2011\)](#) e [Goodfellow, Bengio e Courville \(2016\)](#) descrevem alguns parâmetros na construção e treinamento das RNAs, cuja variação e consequentes combinações resultam em diversas configurações de redes: as épocas, o número de camadas intermediárias, o número de neurônios em uma camada intermediária (muitos podem causar *overfitting*, enquanto poucos podem causar *underfitting* e a taxa de aprendizado). É importante considerar que não é parte do objetivo deste trabalho encontrar a melhor configuração de hiper-parâmetros para a construção das redes, mas sim, propor modelos válidos para o contexto de IP.

Existem várias possibilidades para se escolher os melhores parâmetros adequados aos modelos. Para escolher o número de neurônios por camadas e o número de camadas, é possível realizar validação cruzada com *k-fold* (GOODFELLOW; BENGIO; COURVILLE, 2016) para diferentes configurações de máquinas e identificar a que teve maior acurácia na validação dentro do conjunto de dados de treino, para poder realizar o teste com esta topologia. Entretanto, devido ao tamanho do conjunto de dados, foi desconsiderada a necessidade de múltiplas validações, deixando a qualidade da acurácia para a proporção de dados entre os conjuntos de treino e teste. Devido ao levantado por Cybenko (1989) e à disponibilidade de processamento para treino, a MLP foi definida para ter 100 neurônios em uma única camada intermediária.

A taxa de aprendizado pode ser fixa, ou variável, que começa alta e decresce em uma exponencial a cada iteração, de forma que inicialmente a máquina aprenda rápido e no fim, apenas realize ajustes finos. Há ainda a possibilidade de ajustar a taxa conforme o modelo converge a função de perda. Entretanto, para fins de simplificação, foi determinada uma taxa constante, equivalente a 0.005. Quanto aos outros parâmetros, foram estabelecidas 250 épocas (devido ao resultado da análise dos conjuntos padronizados/normalizados, convergindo aproximadamente nesta iteração).

3.3.2 Treinamento, validação e teste

Uma vez criada a topologia da rede, os dados foram separados em conjuntos de treino e testes, sendo necessário decompor a matriz de dados segundo uma proporção apropriada para que a máquina se especialize até certo ponto com a etapa de treino e realize um bom teste. Foi adotada a proporção de 7:3 para treino e teste, realizada utilizando a função *train_test_split* (SCIKIT-LEARN PROJECT, 2023), que proporciona a separação sem repetição de dados e permite configurar um *seed* para replicar a aleatoriedade com a qual os dados foram divididos mesmo em execuções futuras.

Funções de perda são utilizadas para comparar o valor esperado durante o treinamento com o valor atingido. Existem diferentes tipos de funções de perda adequadas para diversas situações. Para problemas de regressão e classificação, foram empregadas, respectivamente, o Erro Médio Quadrático e a Entropia Cruzada Binária. Tais funções podem ser otimizadas por meio de um otimizador, visando minimizar a perda. No caso dos modelos abordados, o otimizador escolhido foi o Adam.

A avaliação das redes ocorre durante a fase de teste, em que novos dados são alimentados na rede, sem que esta modifique seus pesos. Os métodos selecionados para essa avaliação foram a acurácia, matriz de confusão, que ilustra o número de previsões corretas e incorretas em cada classe (“atende” e “não atende”) e a curva *ROC*, para o problema de classificação, utilizando na regressão o *MSE* e R^2 , conforme definido em (FACELI et al., 2011).

3.3.3 Configurações propostas

Considerando o exposto nas seções anteriores, incluindo as Figuras 13 e 14, as configurações planejadas para simulação, levando em consideração topologias, hiperparâmetros e algoritmos, foram:

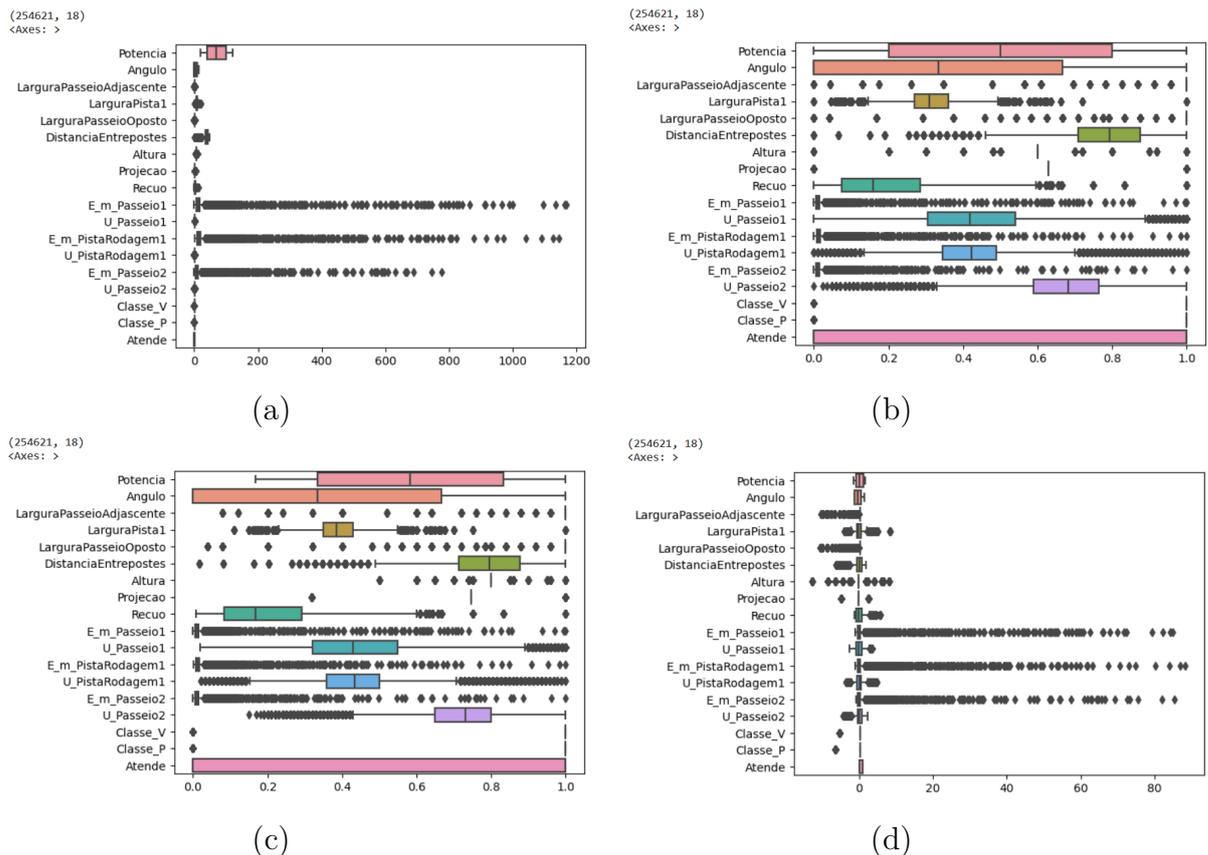
1. **MLP** de regressão: 250 épocas, uma camada intermediária com 100 neurônios, com 9 neurônios de entrada e 6 de saída, ativação sigmoidal na camada de saída e *ReLU* na entrada;
2. **MLP** de classificação: 250 épocas, uma camada intermediária com 100 neurônios, com 8 neurônios de entrada e 1 de saída, ativação sigmoidal na camada de saída e *ReLU* na entrada;

4 Resultados e Discussões

4.1 Normalização e padronização de dados

A Figura 15(a) apresenta o *boxplot* do conjunto ajustado de acordo com as transformações citadas anteriormente. É possível identificar no canto esquerdo superior da figura a mudança da forma do conjunto de dados após a remoção e divisão de colunas, bem como eliminação de erros, para 254621x18. Destaca-se a dificuldade em identificar os intervalos interquartis dos *boxplots*, devido às escalas diferentes de cada atributo, com os valores de E entre próximo de $0\text{lm}/\text{m}^2$ e próximo a $1.200\text{lm}/\text{m}^2$, ou $800\text{lm}/\text{m}^2$, constituindo as colunas com mais *outliers*, enquanto a imediatamente maior, “Potência”, não chega a 200W .

Fig. 15 – Distribuição dos atributos.



Fonte: Elaborado pelo autor.

Não foi feita uma remoção de *outliers*, pois, embora o sejam sob o ponto de vista estatístico, ainda são valores possíveis de projetos de IP, em um conjunto que não necessariamente estava bem balanceado. Era necessário, entretanto, evitar o enviesamento dos dados na atribuição de pesos nas etapas seguintes, então foram realizadas as três

normalizações/padronizações propostas por [Faceli et al. \(2011\)](#). Utilizando-se apenas dos dados necessários à rede de classificação, foram resultantes os quatro conjuntos de dados seguintes:

- O conjunto de dados original após os ajustes, na Figura 15(a);
- O conjunto com as colunas normalizadas por um intervalo de valores mínimo e máximo, representado na Figura 15(b);
- O conjunto com as colunas normalizadas pelo maior valor em cada coluna, representado na Figura 15(c);
- O conjunto padronizando (subtraindo cada valor pela média da coluna e dividindo pelo valor médio da mesma), representado na Figura 15(d). Neste em particular, houve o cuidado de não padronizar a coluna "Atende", para não afetar a saída binária do classificador e comprometer o uso de função de ativação.

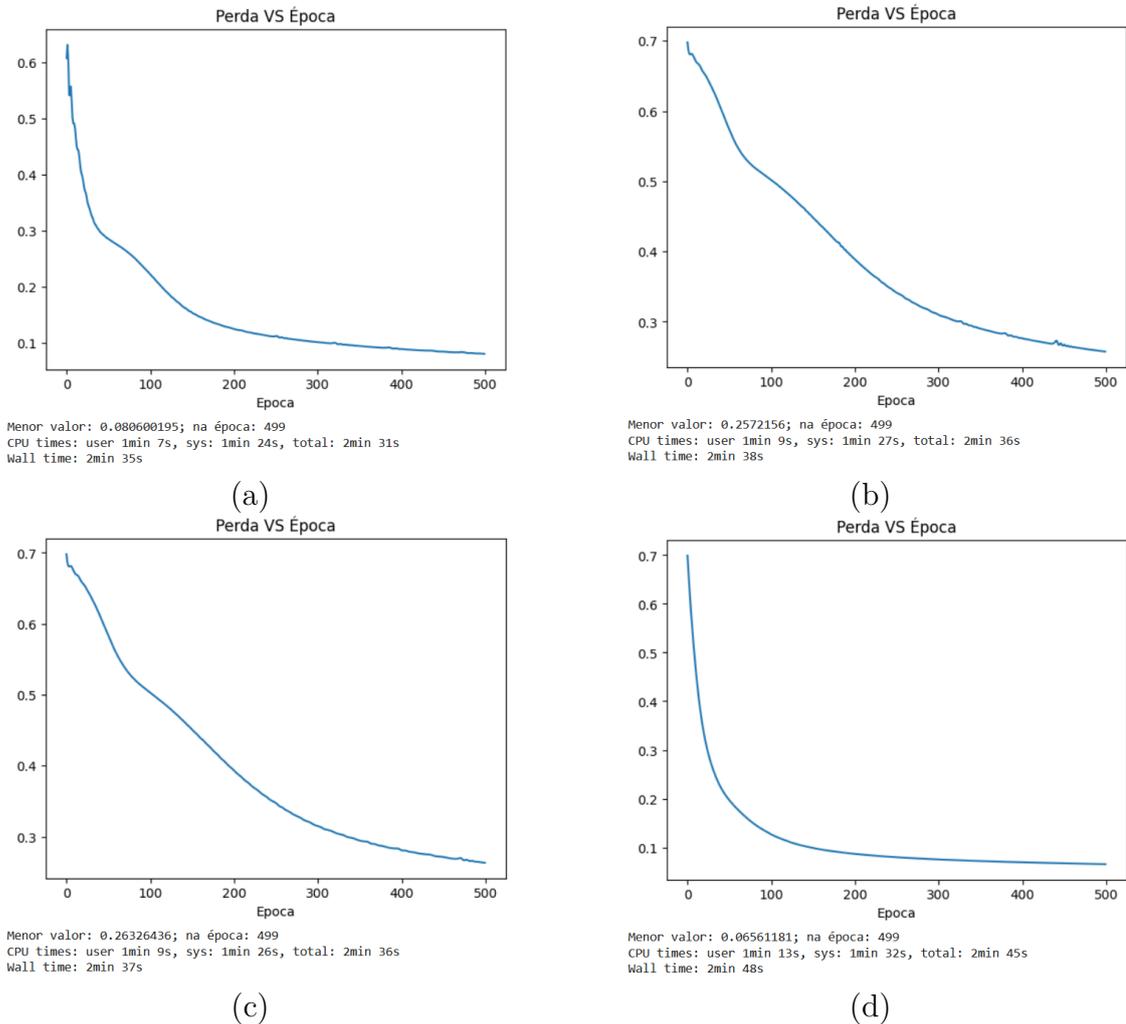
Percebe-se, a partir das Figuras 15(a), 15(b), 15(c) e 15(d) que houve uma certa similaridade em pares entre os conjuntos, sendo os de normalização muito parecidos e o de padronização respeitando o formato dos *boxplots* do conjunto original, embora tenha realizado alterações importantes. A principal mudança na padronização em relação à forma original foi na escala, que reduziu para algo próximo de -20 até 80, deixando os dados bem mais equilibrados e possibilitando, inclusive, perceber outros *boxplots* ao reduzir em muito os vieses que poderiam ter ocorrido pelas colunas de iluminância.

Para avaliar qual melhor conjunto de ser utilizado, foi construída uma rede [MLP](#) de classificação com a saída "Atende", as entradas sendo todas as colunas exceto *Es*, *Us* e classes de vias, com uma camada intermediária, 100 neurônios na camada, utilizando *backpropagation* de 500 épocas, taxa de aprendizado de 0.005 e *weight-decay* de 0.0005. Treinando os respectivos conjuntos de dados na topologia (optou-se por não realizar a *cross-validation*, uma vez que o conjunto seria o mesmo para as quatro execuções), algoritmos e hiper-parâmetros descritos, houve como resultado da função de perda o que se expressa nas Figuras 16(a), 16(b), 16(c) e 16(d).

As Figuras 16(a), 16(b), 16(c) e 16(d), evidenciam que, considerando o tempo de treinamento como praticamente o mesmo, os menores valores de perda alcançados (respectivamente, 0,0806, 0,2572, 0,2633 e 0,0656) e a convergência da função de perda evidenciada de maneira contínua, o conjunto de dados que melhor contribuiu para um bom modelo com a definida topologia foi o de padronização, tendo inclusive chegado a valores aceitáveis de perda muito antes das 500 épocas definidas.

Estabelece-se uma relação sobre o resultado das funções de perda com o que foi visto nas Figuras 15(a), 15(b), 15(c) e 15(d), com os conjuntos de normalização apresentando

Fig. 16 – Gráfico da função de perda ao decorrer de 500 épocas o conjunto de entradas de classificação em MLP.



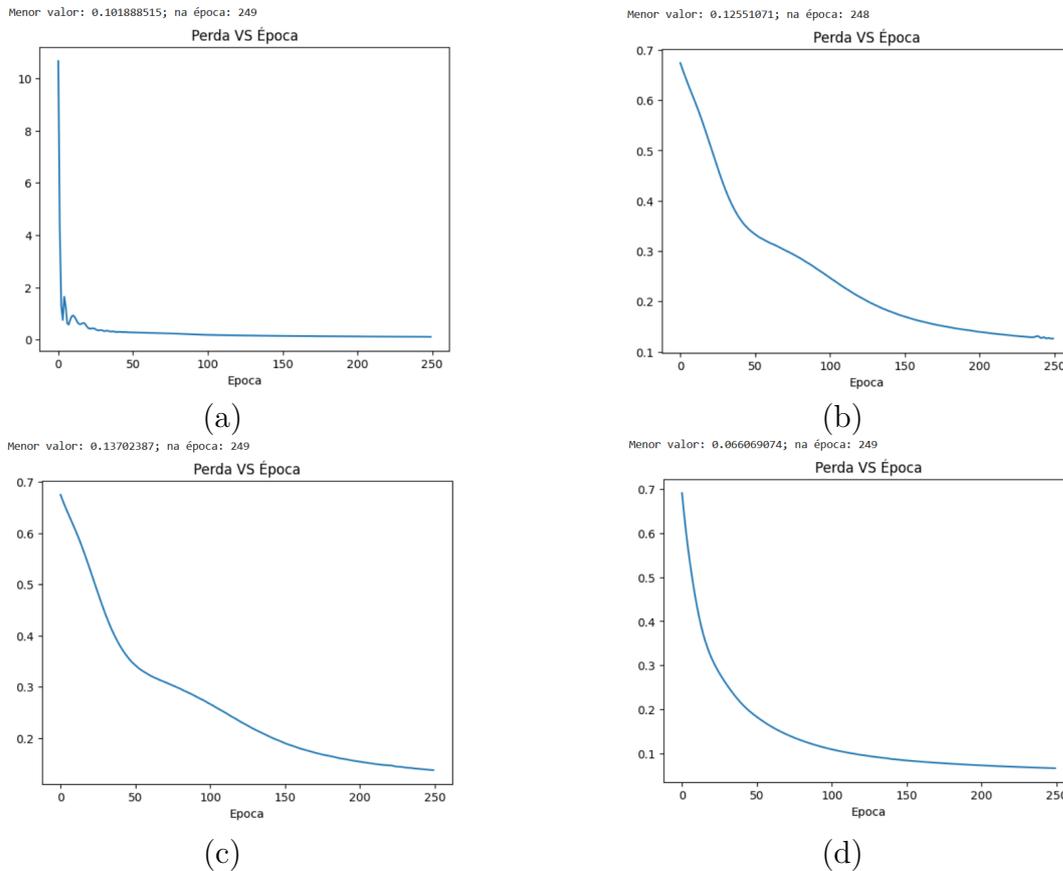
Fonte: Elaborado pelo autor.

gráficos bem parecidos, com os conjuntos original e padronizado possuindo um aspecto similar, mas com o de padronização apresentando um melhor balanceamento, refletindo na suavidade da função de perda ao longo das épocas.

É possível utilizar a mesma lógica ao se aplicar como entrada todas as outras colunas que não sejam “Atende”. Conforme se evidencia nas Figuras 17(a), 17(b), 17(c) e 17(d), a análise, não considerando a grande diferença de escala da Figura 17(a) para as outras, mantém a resposta para o conjunto anterior.

Logo, todas as análises descritas nas próximas seções consideram o conjunto de dados padronizados como o conjunto de dados utilizado nas implementações das RNAs.

Fig. 17 – Gráfico da função de perda ao decorrer de 500 épocas utilizando o conjunto inteiro em MLP de classificação.



Fonte: Elaborado pelo autor.

4.2 Resultados da construção dos modelos

A partir deste ponto, são tratadas as configurações descritas no Capítulo 3, consistindo de duas implementações:

- MLP de regressão;
- MLP de classificação;

Estas implementações têm nesta seção os gráficos da função de perda em decorrência das épocas exibidos como resultados das etapas de treinamentos (no caso das redes [MLP](#)), e os parâmetros respectivos à natureza de regressão ou classificação.

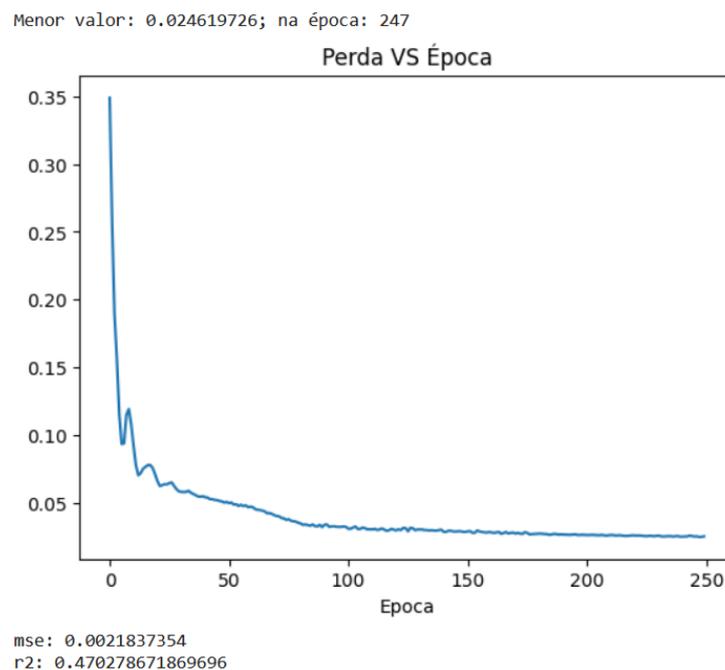
4.2.1 MLP de regressão

A Figura 18 evidencia os resultados da primeira configuração, trazendo o gráfico da função de perda, acima dele a menor perda obtida e sua respectiva época, e os resultados

de avaliação MSE e R^2 . É possível notar uma oscilação no gráfico de perda, principalmente até a 50^a época, um ruído mínimo até a 150^a época e uma estabilização após esta iteração.

Considerando a escala evidenciada para as colunas de saída do modelo de regressão (até 80, devido aos E_s), a perda avaliada em 0,025 é mínima, configurando em um treinamento otimizado, ao mesmo tempo que pode gerar *overfitting* e necessita da avaliação dos outros critérios para qualificá-lo.

Fig. 18 – Gráfico da função de perda ao decorrer de 250 épocas da MLP de regressão.



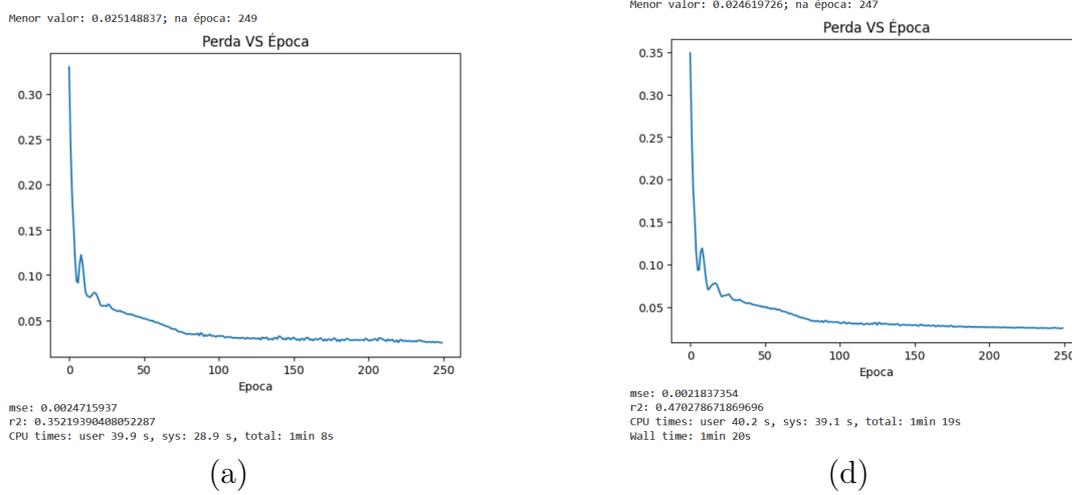
Fonte: Elaborado pelo autor.

O MSE encontrado de 0,0022 e o R^2 de 0,047 encontrados avaliam o modelo implementado de maneiras contrastantes. O MSE muito baixo implica que as previsões estão muito próximas do que se esperava no contexto dos dados reais, entretanto o R^2 denota uma baixa explicação à variabilidade dos dados, o que deve se relacionar ao não balanceamento dos dados e à diferença de escala entre as saídas do modelo de regressão, conforme a Figura 15.

Modificando o conjunto de dados para o normalizado via intervalo e via valor absoluto (não há necessidade em testar o conjunto original), encontra-se o evidenciado nas Figuras 19(a) e 19(b).

Considerando os novos valores de MSE e R^2 , a hipótese da escala de dados é descartada, necessitando de mais ajustes para se encontrar uma MLP de regressão que com melhor R^2 .

Fig. 19 – Gráfico da função de perda ao decorrer de 250 épocas da MLP de regressão utilizando dados normalizados.

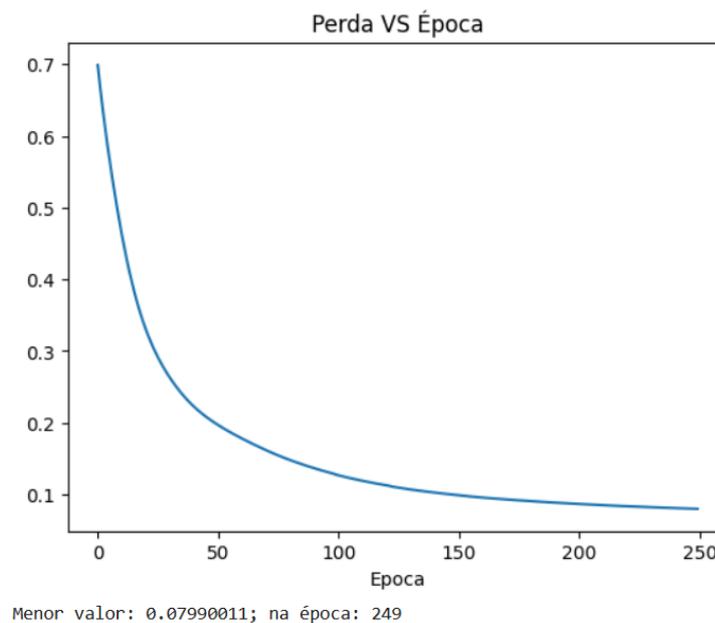


Fonte: Elaborado pelo autor.

4.2.2 MLP de classificação

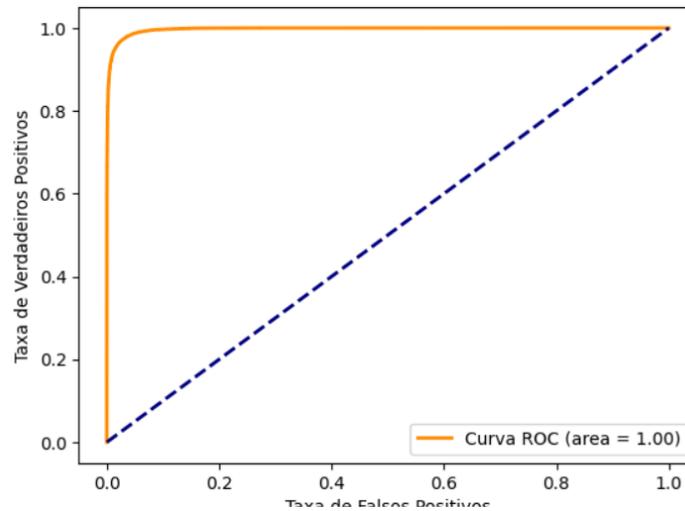
A Figura 20 evidencia os resultados da segunda configuração, trazendo o gráfico da função de perda, abaixo dele a menor perda obtida e sua respectiva época, enquanto a Figura 21 mostra a acurácia, matriz de confusão e curva ROC para o mesmo conjunto de dados, algoritmo e topologia.

Fig. 20 – Gráfico da Função de perda ao decorrer de 250 Épocas da MLP de classificação.



Fonte: Elaborado pelo autor.

Fig. 21 – Curva ROC e área AUC da MLP de classificação.



Fonte: Elaborado pelo autor.

A curva da função de perda se assemelha à obtida na seção anterior, o que é esperado. Considerando a entrada binária, a perda ter chegado a 0,08 implica em um modelo muito bem treinado, e a acurácia em 97,26%, bem como a curva *ROC* (com uma *AUC* igual a 1) e a matriz de confusão (considerando bons índices para as taxas de verdadeiros negativos e verdadeiros positivos, relativos às classes de “Atende” e “Não Atende”), mostram que ele pode ser sim aplicado ao contexto de *IP* para classificar se um conjunto de parâmetros de *E* e *U* atende à *NBR* 5101.

Tab. 6 – Matriz de confusão da MLP de classificação.

	Classe Predita Positiva	Classe Predita Negativa
Classe Real Positiva	31125	1124
Classe Real Negativa	967	43171

5 Conclusão

5.1 Conclusões

Considerando os resultados observados e discutidos no capítulo anterior, pode-se considerar que os objetivos estabelecidos que motivaram este trabalho foram concluídos. A revisão bibliográfica efetuada foi muito importante para embasamento teórico do contexto de **IP** e também para a implementação dos modelos. Através da análise gráfica, utilizando as diferentes formas do conjunto de dados quanto à normalização e padronização, foi possível mostrar a influência das escalas dos dados contidos no conjunto sobre a forma com a qual a **MLP** respondia ao ajustar os pesos em um modelo resultante. Por fim, embora a implementação dos modelos **ELM** tenha apresentado resultados inesperados quanto à eficácia (na regressão e na classificação) foi possível implementar, treinar e avaliar os modelos de redes neurais **MLP**, tendo sido um MSE de 0,002 na regressão e acurácia de 97,26% na classificação, servindo para nos contextos, tanto de regressão quanto de classificação para projetos luminotécnicos.

5.2 Sugestões para pesquisas futuras

Como possíveis desdobramentos deste trabalho, é possível sugerir algumas possibilidades. A primeira, utilizar diferentes hiperparâmetros em busca de uma solução melhor, como a taxa de aprendizado variável ou adaptativa à convergência da função de perda, levantada no Capítulo 3. Evoluindo a proposta inicial deste trabalho, também é possível modificar um pouco o problema para, a partir de um conjunto de parâmetros que não atendem à **NBR 5101**, encontrar a configuração mais próxima da parametrização inicial cujos valores sejam adequados à norma. Uma terceira sugestão seria a análise comparativa direta em relação aos softwares de mercado voltados à simulação de cenários de **IP**, verificando suas acurácias e tempos frente às topologias de redes neurais utilizadas neste trabalho, ou, ainda, topologias diferentes.

Referências

ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE ILUMINAÇÃO. *Uso de LED pode reduzir em 50% o consumo de energia*. 2015. Disponível em: <https://www.abilux.com.br/noticia/uso_de_led_pode_reduzir_em_50_o_consumo_de_energia/>. Citado na página 19.

ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE ILUMINAÇÃO. *Guia para Iluminação Pública - Volume 1*. [S.l.], 2021. Disponível em: <https://www.abilux.com.br/docs/Abilux_Guia_IluminacaoPublica_2021_volume-01.pdf>. Citado 4 vezes nas páginas 19, 20, 27 e 29.

ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE ILUMINAÇÃO. *Guia para Iluminação Pública - Volume 2*. [S.l.], 2021. Disponível em: <https://www.abilux.com.br/docs/Abilux_Guia_IluminacaoPublica_2021_volume-02.pdf>. Citado na página 29.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *Norma Brasileira 5101: Iluminação pública - Procedimento*. 2018. Disponível em: <www.abnt.org.br>. Citado 5 vezes nas páginas 19, 23, 24, 28 e 29.

BAKRI, B. I. et al. USING DEEP LEARNING TO DESIGN AN INTELLIGENT CONTROLLER FOR STREET LIGHTING AND POWER CONSUMPTION. *Eastern-European Journal of Enterprise Technologies*, Technology Center, v. 3, n. 8-117, p. 25–31, 2022. ISSN 17294061. Disponível em: <https://www.researchgate.net/publication/361877154_Using_deep_learning_to_design_an_intelligent_controller_for_street_lighting_and_power_consumption>. Citado na página 38.

BENGIO, Y.; LECUN, Y. *Convolutional Networks for Images, Speech, and Time-Series*. [S.l.], 1997. Disponível em: <<https://www.researchgate.net/publication/2453996>>. Citado na página 38.

CYBENKO, G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*, v. 2, n. 4, p. 303–314, 12 1989. Disponível em: <https://web.njit.edu/~usman/courses/cs675_fall18/10.1.1.441.7873.pdf>. Citado 2 vezes nas páginas 37 e 49.

FACELI, K. et al. *Inteligência artificial: uma abordagem de aprendizado de máquina*. [S.l.]: LTC, 2011. Citado 15 vezes nas páginas 20, 30, 31, 32, 33, 34, 35, 36, 37, 41, 46, 47, 48, 49 e 52.

GARCES-JIMENEZ, A. et al. Analysis of Artificial Neural Network Architectures for Modeling Smart Lighting Systems for Energy Savings. *IEEE Access*, Institute of Electrical and Electronics Engineers Inc., v. 7, p. 119881–119891, 2019. ISSN 21693536. Disponível em: <https://www.researchgate.net/publication/334778585_Analysis_of_Artificial_Neural_Network_Architectures_for_Modeling_Smart_Lighting_Systems_for_Energy_Savings>. Citado na página 39.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016. Disponível em: <<https://www.deeplearningbook.org/>>. Citado 11 vezes nas páginas 30, 31, 32, 34, 35, 36, 37, 38, 41, 48 e 49.

HUANG, G. B.; ZHU, Q. Y.; SIEW, C. K. Extreme learning machine: A new learning scheme of feedforward neural networks. In: *IEEE International Conference on Neural Networks - Conference Proceedings*. [s.n.], 2004. v. 2, p. 985–990. ISBN 0780383591. ISSN 10987576. Disponível em: <<https://ieeexplore.ieee.org/document/1380068>>. Citado na página 38.

HUANG, G. B.; ZHU, Q. Y.; SIEW, C. K. Extreme learning machine: Theory and applications. *Neurocomputing*, v. 70, n. 1-3, p. 489–501, 12 2006. ISSN 09252312. Disponível em: <https://web.njit.edu/~usman/courses/cs675_fall19/ELM-NC-2006.pdf>. Citado 2 vezes nas páginas 38 e 41.

LEE, Y.; ZHANG, H.; ROSA, J. Street Lamp Fault Diagnosis System Based on Extreme Learning Machine. In: *IOP Conference Series: Materials Science and Engineering*. Institute of Physics Publishing, 2019. v. 490, n. 4. ISSN 1757899X. Disponível em: <<https://iopscience.iop.org/article/10.1088/1757-899X/490/4/042053/meta>>. Citado na página 38.

MCCULLOCH, W. S.; PITTS, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. *The Bulletin of Mathematical Biophysics*, v. 5, n. 4, p. 115–133, 12 1943. ISSN 0007-4985. Disponível em: <<http://link.springer.com/10.1007/BF02478259>>. Citado 2 vezes nas páginas 32 e 35.

MEYER, M. et al. *Lighting Brazilian Cities: Business Models for Energy Efficient Public Street Lighting*. Washington, DC, 2017. Disponível em: <<http://hdl.handle.net/10986/29537>>. Citado na página 19.

MINISTÉRIO DE MINAS E ENERGIA. *Iluminação Pública*. 2022. Disponível em: <<https://www.gov.br/aneel/pt-br/assuntos/iluminacao-publica>>. Citado na página 19.

MINSKY, M.; PAPER, S. A. *Perceptrons*. Cambridge, MA, USA: The MIT Press, 1969. Disponível em: <<https://direct.mit.edu/books/book/3132/perceptronsan-introduction-to-computational>>. Citado na página 35.

ML GLOSSARY. Activation Functions. 2017. Disponível em: <https://ml-cheatsheet.readthedocs.io/en/latest/activation_functions.html>. Citado 2 vezes nas páginas 32 e 33.

MOHANDAS, P.; DHANARAJ, J. S. A.; GAO, X. Z. Artificial Neural Network based Smart and Energy Efficient Street Lighting System: A Case Study for Residential area in Hosur. *Sustainable Cities and Society*, Elsevier Ltd, v. 48, 7 2019. ISSN 22106707. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S2210670718317530>>. Citado na página 39.

NAHID, A. A.; MEHRABI, M. A.; KONG, Y. Histopathological Breast Cancer Image Classification by Deep Neural Network Techniques Guided by Local Clustering. *BioMed Research International*, v. 2018, 2018. Disponível em: <<https://www.semanticscholar.org/CorpusID13872250>>. Citado na página 30.

NEOENERGIA. *Iluminação Pública*. 2021. Disponível em: <<https://www.neoenergia.com/web/bahia/poder-publico/iluminacao-publica>>. Citado na página 19.

OPENAI. *GPT-4 Technical Report*. 2023. Disponível em: <<https://arxiv.org/abs/2303.08774>>. Citado na página 30.

- PYTHON SOFTWARE FOUNDATION. *Python 3.12.0 documentation*. 2023. Disponível em: <<https://docs.python.org/3/>>. Citado na página 41.
- PYTORCH FOUNDATION. *Pytorch Documentation*. 2023. Disponível em: <<https://pytorch.org/docs/stable/index.html>>. Citado 3 vezes nas páginas 20, 41 e 48.
- QLUZ. *ESG na modernização da iluminação pública*. 2022. Disponível em: <<https://www.qluzpalhoca.com.br/esg/>>. Citado na página 19.
- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, v. 65, n. 6, p. 386–408, 1958. ISSN 1939-1471. Disponível em: <<http://doi.apa.org/getdoi.cfm?doi=10.1037/h0042519>>. Citado na página 35.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *nature*, Nature Publishing Group UK London, v. 323, n. 6088, p. 533–536, 1986. Citado 2 vezes nas páginas 35 e 36.
- SANTOS, W. F. S.; COSTA, V. S. *Street Lighting Simulation based on Extreme Learning Machine*. [S.l.], 2023. Disponível em: <<https://www.researchgate.net/publication/370466269>>. Citado 2 vezes nas páginas 38 e 39.
- SCIKIT-LEARN PROJECT. *User Guide*. 2023. Disponível em: <https://scikit-learn.org/stable/user_guide.html>. Citado 3 vezes nas páginas 41, 48 e 49.
- WANG, J. et al. A review on extreme learning machine. *Multimedia Tools and Applications*, Springer, v. 81, n. 29, p. 41611–41660, 12 2022. ISSN 15737721. Disponível em: <<https://link.springer.com/article/10.1007/s11042-021-11007-7>>. Citado na página 38.