

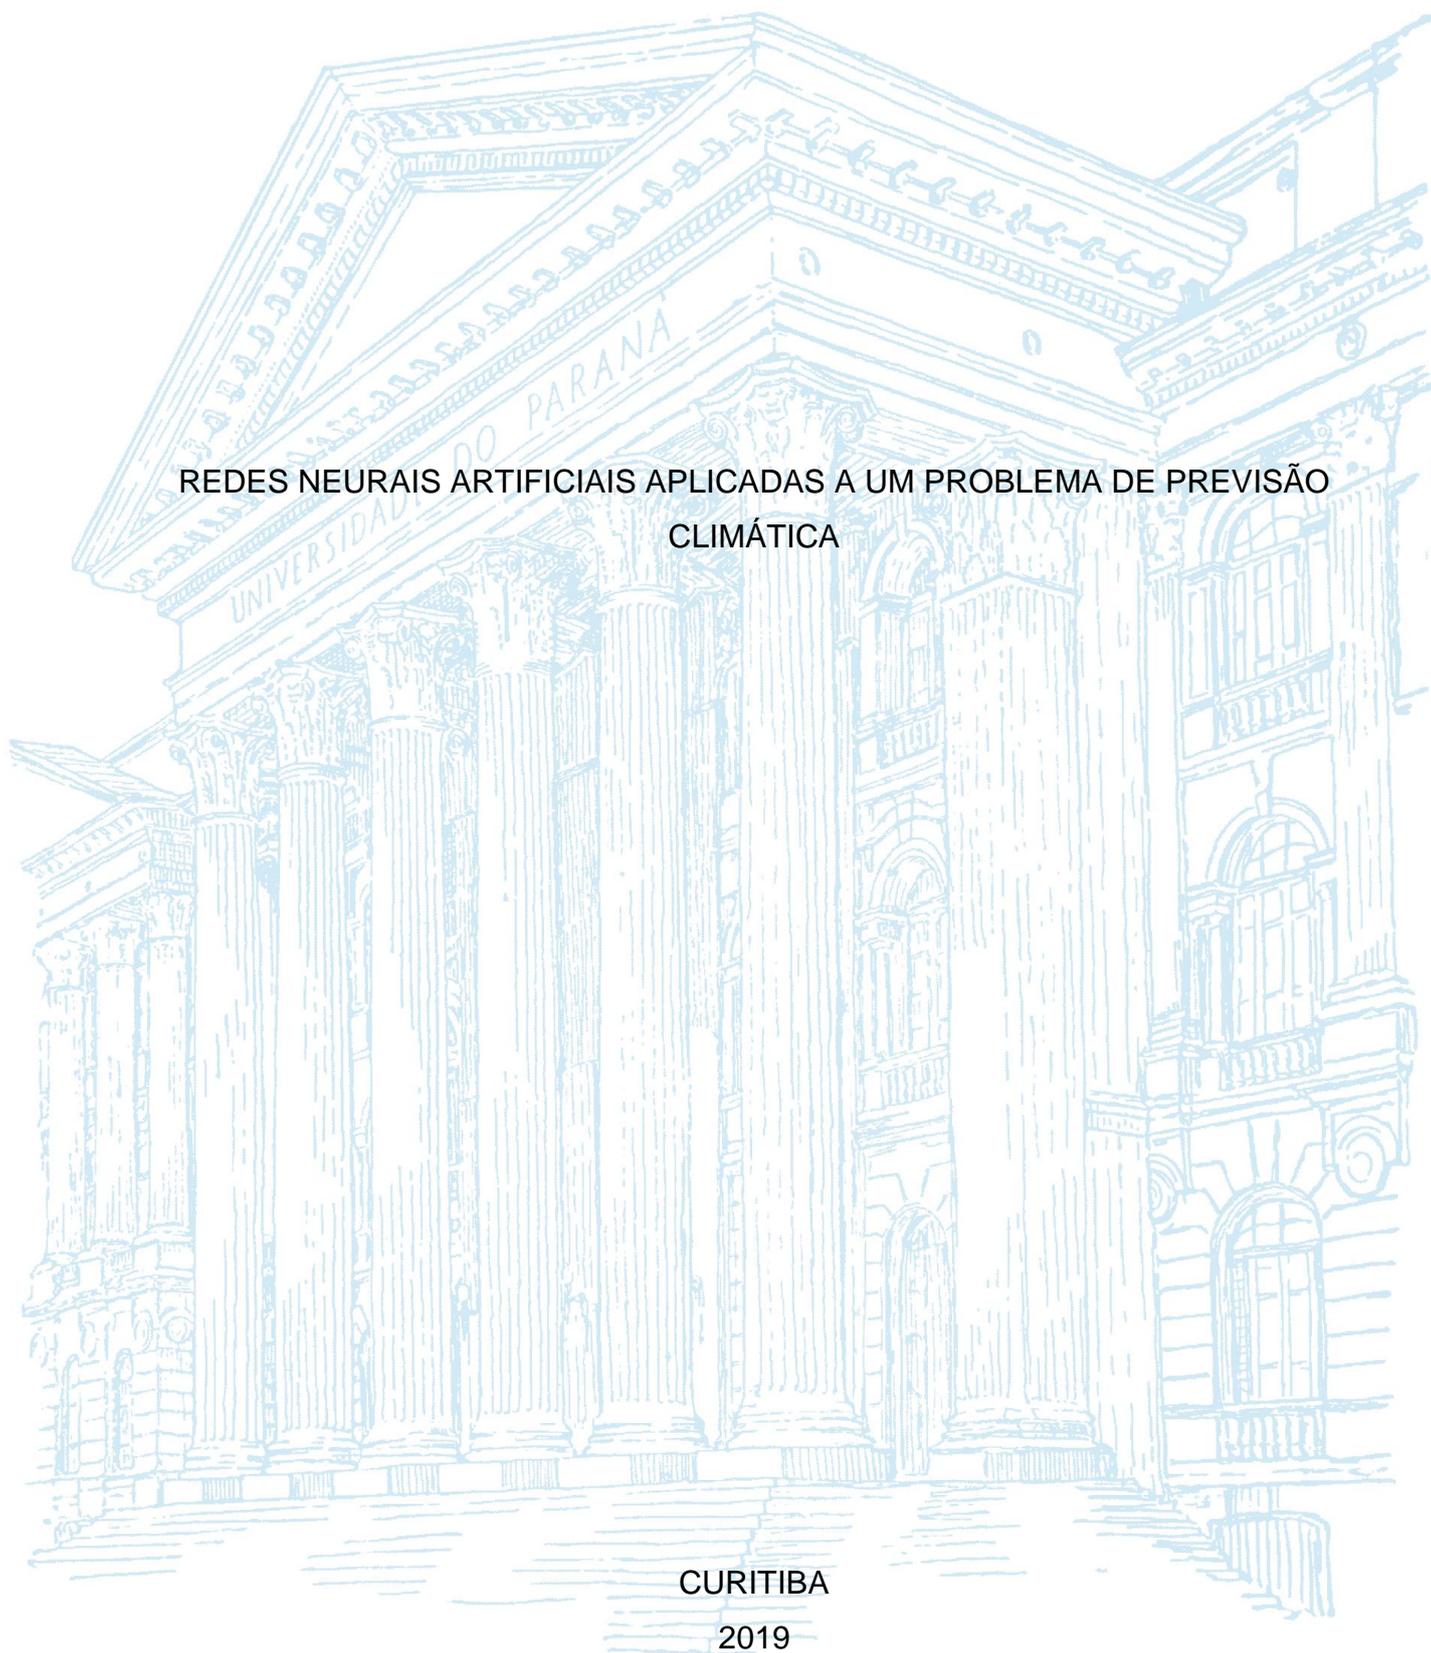
UNIVERSIDADE FEDERAL DO PARANÁ

ALBERTO PURKOTE

REDES NEURAS ARTIFICIAIS APLICADAS A UM PROBLEMA DE PREVISÃO
CLIMÁTICA

CURITIBA

2019



ALBERTO PURKOTE

REDES NEURAS ARTIFICIAIS APLICADAS A UM PROBLEMA DE PREVISÃO
CLIMÁTICA

Trabalho de Conclusão de Curso apresentado ao curso de Engenharia de Produção, Setor de Tecnologia, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Bacharel em Engenharia de Produção.

Orientadora: Profa. Dra. Mariana Kleina.

CURITIBA

2019

RESUMO

O presente trabalho visa aplicar duas Redes Neurais Artificiais (RNA), como um estudo de caso, uma para previsão de chuva no dia seguinte, e outra rede para quantidade em milímetros da precipitação. Para obtenção dos resultados utilizou-se o software R, com o pacote RSNNS. Os resultados obtidos são comparados com os valores reais, provenientes de uma base de dados sobre condições meteorológicas na Austrália, com 59.771 observações e 24 variáveis. Com a base inicial de 20 variáveis e 80% das observações para treinamento e os 20% restantes utilizados para testes. A função de ativação utilizada foi a sigmoide logística, com a quantidade de neurônios na camada oculta variando de 1 a 50. Por meio da aplicação do teste de correlação de Pearson quatro variáveis independentes foram consideradas redundantes e eliminadas da base de dados. A primeira RNA, para previsão de chuva no dia seguinte, com 47 neurônios na camada oculta, obteve valor de erro foi igual à zero para o conjunto de teste. A segunda RNA, para previsão de quantidade em milímetros de chuva para o dia seguinte, com a melhor configuração de neurônios na camada oculta igual 36, teve valor do erro médio de 8,077 mm em sua previsão para o conjunto de teste, que possui como valor médio 2,397 mm. Portanto, percebe-se que houve resultados satisfatórios para a primeira rede, e uma diferença significativa da segunda rede, quando comparados com os valores reais da base de dados.

Palavras-Chave: Redes Neurais Artificiais. Previsão de chuvas. Previsão do tempo.

LISTA DE FIGURAS

FIGURA 1 – REDE NEURAL ARTIFICIAL	10
FIGURA 2 – GRÁFICO DA FUNÇÃO SIGMOIDE LOGÍSTICA.....	12
FIGURA 3 – QUANTIDADE REAL E PREVISTA PELA RNA.	24

LISTA DE TABELAS

TABELA 1 – VARIÁVEIS UTILIZADAS.....	16
TABELA 2 – RESULTADO DA CORRELAÇÃO DE VARIÁVEIS.....	19
TABELA 3 – RESULTADOS RNA PARA PREVISÃO DE OCORRÊNCIA DE CHUVA NO DIA SEGUINTE.	22
TABELA 4 – RESULTADOS RNA PREVISÃO EM MILIMETROS DE CHUVA NO DIA SEGUINTE.....	20

LISTA DE ABREVIATURAS OU SIGLAS

MLP - *Multi Layer Perceptron*

RNA - *Redes Neurais Artificiais*

SNNS - *Stuttgart Neural Network Simulator*

LISTA DE SÍMBOLOS

$\varphi(\cdot)$ – função de ativação

b – *bias*

Σ – somatório de números

W – peso

α – taxa aprendizagem

SUMÁRIO

1 INTRODUÇÃO	8
1.1 JUSTIFICATIVA	9
1.2 OBJETIVOS	9
1.2.1 Objetivo geral	9
1.2.2 Objetivos específicos.....	9
2 REVISÃO DE LITERATURA	10
2.1 REDES NEURAS ARTIFICIAS	10
2.2 MEDIDAS DE ERROS	15
3 METODOLOGIA	16
4 RESULTADOS.....	19
4.1 REDE NEURAL ARTIFICIAL PARA PREVISÃO DE OCORRÊNCIA DE CHUVA NO DIA SEGUINTE.....	22
4.2 REDE NEURAL ARTIFICIAL PARA PREVISÃO EM MILIMETROS DE CHUVA NO DIA SEGUINTE.....	23
5 CONSIDERAÇÕES FINAIS.....	25
REFERÊNCIAS.....	26

1 INTRODUÇÃO

A inteligência artificial é uma área do conhecimento que teve grande expansão e tem despertado interesse nas últimas décadas. Por meio de funções matemáticas e algoritmos computacionais ações como classificação, predição e tomada de decisão são úteis para resolução de problemas cotidianos e/ou com grande volume de dados.

Para Norvig e Russel (2014) o avanço e aplicação da inteligência artificial é importante para a tomada de decisão para organizações, investimentos e governos. Ainda segundo os autores, é uma área do conhecimento em expansão devido à quantidade e complexidade de dados e problemas a serem resolvidos ou analisados.

Recentemente a indústria 4.0 incorporou como um dos componentes a inteligência artificial, conforme afirmam Magone e Mazali (2016), integrada ao sistema produtivo e fornecendo informações e controle sobre os processos.

Como principais vantagens do uso da inteligência artificial, conforme Popkova, Ragulina e Bogoviz (2019), estão: a redução de riscos, potencial de fornecer grande quantidade de soluções viáveis, eliminação de falhas humanas, otimização de recursos e tarefas.

No presente trabalho será utilizada a técnica de inteligência artificial: Redes Neurais Artificiais (RNA), visando à aplicação em modelos de previsão de chuvas e comparação dos resultados obtidos.

A geração de modelos de previsão de precipitações são úteis para o dimensionamento e manejo agrícola, provendo informações úteis para os produtores e agricultores (DANTAS et al., 2017).

Conforme Moreira et al. (2006) destaca que esses estudos são relevantes para estimativa de erosão de solo, com os resultados sendo utilizados por engenheiros para projetos e obras de infraestrutura, e o uso das RNA têm aplicabilidade para essa finalidade.

A precisão de chuva relacionada com vazão resultante é importante para geração de energia elétrica e abastecimento de água, segundo enfatizam Figueiredo et al. (2007), permitindo o manejo adequado de recursos hídricos e operação eficiente de unidades de geração de energia e reservatórios. As RNA podem ser

utilizadas para essa aplicação segundo Ferreira (2012), fornecendo resultados satisfatórios para a tomada de decisão e operação de usinas hidrelétricas.

1.1 JUSTIFICATIVA

A aplicação de métodos de inteligência artificial para apoio e tomada de decisão é fundamental para planejamento de investimentos, desenvolvimento de atividades econômicas e gestão dos recursos envolvidos. Nesse âmbito, o presente trabalho é um estudo de caso, visando verificar a aplicabilidade ao problema proposto e análise dos resultados obtidos. A escolha da base de dados foi devido à disponibilidade, acesso e quantidade de dados no formato CSV, com a base de chuvas na Austrália atendendo aos requisitos anteriormente citados.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Aplicar RNA para predição de chuvas na Austrália a partir de uma base de dados inicial.

1.2.2 Objetivos específicos

- Definir os parâmetros envolvidos na RNA;
- Realizar o treinamento e teste das RNA;
- Analisar os resultados obtidos e comparar com valores reais;

2 REVISÃO DE LITERATURA

2.1 REDES NEURAIS ARTIFICIAS

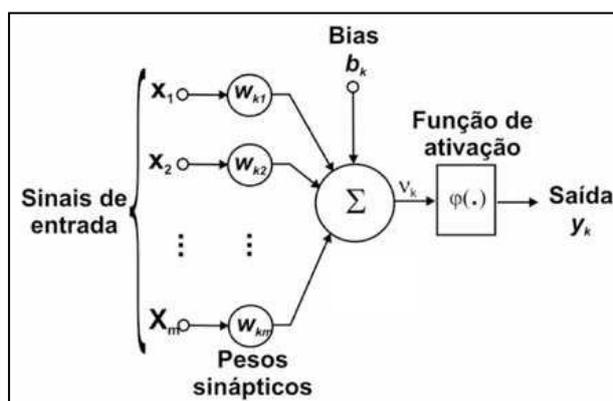
De acordo com Lima, Pinheiro e Oliveira (2014) as redes neurais artificiais são modelos computacionais com potencial de aprendizagem e que podem ser utilizados para reconhecer padrões, agrupar, separar ou organizar dados por meio de uma estrutura de processamento paralelo. Esses modelos são compostos por neurônios, que calculam determinadas funções matemáticas, e são interligados em uma ou mais camadas por meio de conexões (BRAGA et al., 2000).

Os modelos computacionais citados anteriormente foram inspirados no funcionamento do cérebro e neurônio biológico humano, conforme salientam Castro e Ferrari (2016). Por meio de sinais e estímulos a célula obtém como resposta um impulso nervoso resultante. Ou seja, possui um modelo de várias entradas, equivalentes aos estímulos e sinais, e saída única, correspondendo à resposta, obtida pelo processamento e cálculos a partir dos dados de entrada, configurando o modelo do neurônio artificial (KOVÁCS, 2006).

Conforme Yegnanarayana (2006), o primeiro modelo de neurônio foi proposto em foi 1943 por McCulloch e Pitts. O processo de aprendizagem ocorre devido à capacidade de adaptação dos pesos da rede por meio da interação com o meio externo, ou seja, dados utilizados para o treinamento, resultando em uma melhoria gradativa dos pesos baseado no conjunto de dados utilizado (REZENDE, 2005).

Uma rede neural pode ser representada graficamente conforme a FIGURA 1.

FIGURA 1 – REDE NEURAL ARTIFICIAL



FONTE: Adaptado de Haykin (2001).

As variáveis x_1, x_2, \dots, x_m são os sinais de entradas do neurônio. Em cada entrada há um elemento de multiplicação chamado peso $w_{k_1}, w_{k_2}, \dots, w_{k_m}$ do neurônio k , denominado peso sináptico e reflete o conhecimento da rede e ponderara a entrada recebida por cada neurônio.

A variável u_k é à saída do combinador linear e pode ser calculada pela Equação 1. Com m sendo a quantidade de pesos sinápticos do modelo.

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j \quad (1)$$

A variável b_k é chamada de *bias* e atua como um elemento para aumentar ou reduzir o grau de liberdade dos ajustes dos pesos, como apresentado na Equação 2.

$$v_k = u_k + b_k \quad (2)$$

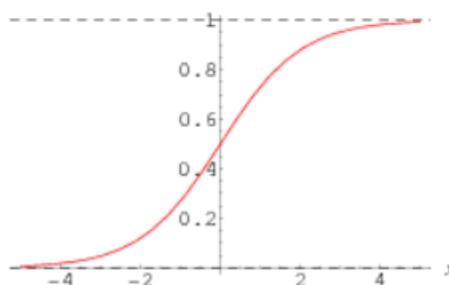
A função de ativação é representada por $\varphi(\cdot)$ e determina a saída de um neurônio e permitem as RNA identificar relações lineares ou não entre as entradas e saídas. O y_k é a saída do neurônio, que pode ser determinado pela Equação 3.

$$y_k = \varphi(u_k + b_k) \quad (3)$$

Existem vários tipos de funções de ativação, segundo Quiles (2004) as principais são: limiar, linear por partes, logística e tangente hiperbólica. A função logística, adotada como função de ativação, é definida conforme Equação 4, cujo gráfico está representado na Figura 2.

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (4)$$

FIGURA 2 – GRÁFICO DA FUNÇÃO SIGMOIDE LOGÍSTICA



FONTE: Mathworld (2019).

O treinamento supervisionado é o mais utilizado e se baseia no ajuste dos pesos e *bias* entre as conexões até que o erro esteja abaixo do limite informado e aceito, proveniente da diferença entre a saída obtida e saída esperada.

O erro global (ε) pode ser obtido por meio da Equação 5, com e sendo o erro da iteração.

$$\varepsilon = \frac{1}{N} \sum_{l=1}^N e_l^2(n) \quad (5)$$

O termo N representa o número de elementos do conjunto de treinamento. O termo n é o número da iteração atual do treinamento.

No aprendizado não-supervisionado, no entanto, não existe um supervisor e, como consequência, não é dada a saída desejada. Neste caso, a rede se adapta às regularidades estatísticas das entradas e gera classes automaticamente.

A RNA do tipo MLP (*Multi Layer Perceptron*), utilizada neste trabalho, possui uma ou mais camadas ocultas entre a entrada e saída, e atuam obtendo características e padrões dos dados de entrada. Dessa forma, a rede gera sua própria relação de classificação. Foi idealizada em 1969 por Minsky e Papert, para solução de problemas mais complexos e, nos quais, o perceptron não era eficiente (YEGNANARAYANA,2006).

Porém, conforme Haykin (2001) ressalva, apenas em 1985 as redes neurais de múltiplas camadas começaram a apresentar resultados satisfatórios, devido a problemas nas formulações anteriores.

Para Haykin (2001) as RNA do tipo MLP têm obtido sucesso em diversos problemas por meio do treinamento supervisionado e por meio do algoritmo de retropropagação de erro (*error back-propagation*) com aprendizagem por correção de erro.

O *back-propagation* é composto por duas fases, sendo uma *forward* percorrendo a rede a partir da entrada à saída. A outra etapa é o *backward*, percorrendo a rede da saída para a entrada para ajuste dos pesos e *bias*.

Etapa 1. Propagação *Forward*

Passo 1.1 Inicialização

Definição aleatória de valores entre [-1,1] para os pesos sinápticos da camada oculta w_k e b_k e camada de saída y_k .

Passo 1.2 Ativação – camada oculta

Realiza o somatório, conforme a Equação 6, para cada neurônio k da camada oculta, com n correspondendo a iteração atual do treinamento.

$$v_{k(n)} = \sum_{l=1}^N w_{kj(n)} \cdot x_{j(n)} + b_{k(n)} \quad (6)$$

Na sequência será calculado o valor da função de ativação, expresso na Equação 7, para cada neurônio da camada oculta, com $\varphi(\cdot)$ sendo a função sigmoide logística.

$$y_{k(n)} = \varphi(v_{k(n)}) \quad (7)$$

Passo 1.3 Ativação – camada de saída

Efetua o somatório apresentado na Equação 8 para cada neurônio l da camada de saída, com y_k correspondendo a entrada da camada de saída.

$$v_{l(n)} = \sum_{n=1}^m w_{lj(n)} \cdot y_{k(n)} + b_{l(n)} \quad (8)$$

O cálculo do valor da função de ativação, apresentado na Equação 9, é obtido para cada neurônio da camada de saída.

$$y_{l(n)} = \varphi(v_{l(n)}) \quad (9)$$

Etapa 2. Propagação *Backward*

Passo 2.1 Ajuste dos pesos – Da camada de saída para camada oculta.

O erro da camada de saída é obtido a partir da Equação 10, no qual d_j é o valor esperado de saída e $\varphi'(\cdot)$ é a derivada da função de ativação do neurônio de saída.

$$\delta_{l(n)} = (d_j - y_l) \cdot \varphi'(u_{l(n)}) \quad (10)$$

O ajuste dos pesos é regido pela Equação 11, e a atualização dos pesos sinápticos da camada de saída é obtido pela Equação 12, em que η é a taxa de aprendizagem e α é a taxa de *momentum*.

$$\Delta(w_{l(j)}) = \alpha(w_{l(j)(n-1)}) + \eta \delta_{l(n)} y_{l(n)} \quad (11)$$

$$w_{lj(n+1)} = w_{lj(n)} + \Delta w_{lj(n)} \quad (12)$$

Passo 2.2 Ajuste de pesos – Da camada oculta para a de entrada

O erro é obtido da camada oculta a partir da Equação 13.

$$\delta_{k(n)} = \varphi'(y_{k(n)}) \sum_l \delta_{l(n)} w_{lj(n)} \quad (13)$$

O ajuste de pesos ocorre pela Equação 14, e atualização a partir da Equação 15.

$$\Delta(w_{l(j)}) = \alpha(w_{l(j)(n-1)}) + \eta\delta_{k(n)} y_{k(n)} \quad (14)$$

$$w_{kj(n+1)} = w_{kj(n)} + \Delta w_{kj} \quad (15)$$

2.2 MEDIDAS DE ERROS

Para a previsão da quantidade em milímetros (mm) o erro considerado é a raiz do erro quadrático médio, representado na Equação 16.

$$EQ_{(n)} = \left[\frac{1}{N} \sum_{l=1}^N (Y_{k(n)} - x_{(n)}) \right]^{1/2} \quad (16)$$

Para previsão de chuva, se irá chover no dia seguinte, a soma dos erros em cada iteração foi considerado conforme Equação 17.

$$E_{(n)} = \sum_{l=1}^N (Y_{k(n)} - x_{(n)}) \quad (17)$$

3 METODOLOGIA

A base de dados foi obtida na plataforma Kaggle, uma plataforma que foi adquirida pelo Google em 2017. Atualmente é uma das maiores comunidades de *Data Science* e *Machine Learning*, disponibilizando gratuitamente bases de dados em diversos formatos, como a base de dados do presente trabalho (KAGGLE,2019). O formato CSV foi escolhido devido à facilidade para inserção dos dados no Software R. Os dados representam diariamente as condições meteorológicas locais obtidas de estações de monitoramento existentes na Austrália, entre os fatores analisados estão: pressão, temperatura, direção e velocidade do vento, umidade e evaporação, nebulosidade, milímetros de chuva registrados, totalizando 24 variáveis, conforme Tabela 1.

TABELA 1 – VARIÁVEIS UTILIZADAS

Variável	Descrição
Data	Data da observação
Localização	Estação meteorológica da observação
Temperatura Mínima	Temperatura mínima na data em graus Celsius
Temperatura Máxima	Temperatura máxima na data em graus Celsius
Precipitação	Quantidade de chuva registrada no dia em mm
Evaporação	Taxa de evaporação registrada em 24 horas até as 9h da data de observação
Claridade	Número de horas com luz do Sol na data de observação
Direção da rajada de vento	Direção do vento mais forte registrado na data de observação
Velocidade da rajada de vento	Velocidade em Km/h do vento mais forte registrado na data de observação
Direção dos ventos às 9h	Direção dos ventos às 9h
Direção dos ventos às 15h	Direção dos ventos às 15h
Velocidade dos ventos às 9h	Velocidade do vento em Km /h em média 10 minutos antes das 9h
Velocidade dos ventos às 15h	Velocidade do vento em Km /h em média 10 minutos antes das 15h
Umidade do ar às 9h	Umidade do ar em % às 9h
Umidade do ar às 15h	Umidade do ar em % às 15h
Pressão às 9h	Pressão atmosférica em hPa ao nível do mar às 9h
Pressão às 15h	Pressão atmosférica em hPa ao nível do mar às 15h
Nebulosidade às 9h	Fração do céu ocupada por nuvens às 9h
Nebulosidade às 15h	Fração do céu ocupada por nuvens às 15h
Temperatura às 9h	Temperatura às 9h na data em graus Celsius

Temperatura às 15h	Temperatura às 15h na data em graus Celsius
Precipitação hoje	Variável booleana que indica se houve precipitação (1) ou não (0) na data da observação
Precipitação amanhã em mm	Quantidade em mm de chuva na data seguinte a observação
Precipitação amanhã	Variável booleana que indica se houve precipitação (1) ou não (0) na data da observação

FONTE: O Autor (2019).

Duas redes neurais foram desenvolvidas com objetivos de previsão diferentes: a primeira se choverá no dia seguinte e a segunda para a quantidade da precipitação em milímetros.

Inicialmente a base foi analisada estatisticamente por meio de um teste de correlação entre todas as variáveis, visando eliminar fatores que apresentam características redundantes. Foi realizado o teste de Pearson no software R.

O presente verificou a aplicabilidade de um modelo de previsão de precipitações na Austrália por meio de redes neurais artificiais do tipo Multi Layer Perceptron analisando os resultados obtidos.

O algoritmo RNA tipo MLP teve propagação *backward* com ajuste em relação ao erro. Portanto, o critério de parada foi assim que o erro calculado for menor que o estabelecido. Os pesos iniciais foram aleatórios gerados no próprio software R.

Para a fase de treinamento foram utilizados 80% dos dados da base fornecida, correspondendo a 46.834 observações, e 20% para o teste do algoritmo, totalizando 12.937 observações.

No software R foi utilizado a função *mlp*, existente no pacote RSNNS de redes neurais, sendo considerado por Bergmeir e Benítez (2012) uma alternativa versátil e eficiente para análise do desempenho das RNA.

A função de ativação utilizada na camada oculta é a sigmoide logística, Equação 4, pois apresenta um bom desempenho e resultados satisfatórios para problemas de predição, conforme afirmam Da Silva et al. (2015), Rêgo (2013) e Bocanegra (2002), em suas pesquisas sobre RNA para previsão.

A escolha do número de neurônios na camada oculta foi definida por testes, em um intervalo entre 1 e 50, considerando o erro obtido em cada teste.

O resultado da previsão da RNA foi comparado com os valores reais, por meio da função *predict*, também do pacote *RSNNS*, e calculada a diferença numérica entre o real e previsto.

4 RESULTADOS

Inicialmente a base foi analisada estatisticamente por meio teste de correlação entre todas as variáveis, utilizando o software R, por meio do teste de Pearson, visando simplificar a base de dados com a eliminação das variáveis redundantes. Os resultados estão representados na Tabela 2.

TABELA 2 – RESULTADO DA CORRELAÇÃO DE VARIÁVEIS.

Variáveis	Data	Localização	Temperatura Mínima	Temperatura Máxima	Precipitação	Evaporação	Claridade	Direção da rajada de vento
Data								
Localização	0,07862702							
Temperatura Mínima	0,03969752	0,117247						
Temperatura Máxima	0,02701751	0,1922547	0,7518668					
Precipitação	-0,01994453	-0,001777585	0,1146388	-0,06472571				
Evaporação	0,05627283	0,1034323	0,507789	0,6437262	-0,07139618			
Claridade	0,02228469	0,09589967	0,07629203	0,4611775	-0,2471619	0,3602708		
Direção da rajada de vento	-0,02265578	0,08134395	-0,03122859	-0,01213557	0,006132903	-0,02000375	0,003172675	
Velocidade da rajada de vento	-0,005168865	-0,03167668	0,1325811	0,04768437	0,108223	0,22312	-0,04612121	0,009718407
Direção dos ventos às 9h	-0,01744059	0,02650181	-0,03398255	-0,04612371	0,006837301	-0,04997264	-0,000257337	0,1225265
Direção dos ventos às 15h	-0,02079936	0,0599813	-0,01146703	0,02134571	0,003718156	0,0007523	0,009910665	0,2293376
Velocidade dos ventos às 9h	-0,03483704	-0,08208473	0,1267602	0,005536719	0,05269985	0,2022668	-0,006108184	-0,01413245
Velocidade dos ventos às 15h	-0,02826972	-0,06486926	0,1487871	0,02575697	0,04339985	0,139995	0,04043813	-0,005673829
Umidade do ar às 9h	-0,0310524	-0,1345402	-0,1833702	-0,4951036	0,2599446	-0,5482336	-0,4977736	-0,01529564
Umidade do ar às 15h	-0,00910929	-0,1284548	0,07153777	-0,4437075	0,2775573	-0,4107029	-0,6270654	-0,03465923
Pressão às 9h	0,02535823	-0,1335537	-0,4881998	-0,3649372	-0,1782163	-0,3094325	0,03582221	-0,0372238
Pressão às 15h	0,02575197	-0,157148	-0,5055053	-0,4633398	-0,134701	-0,3342604	-0,02778856	-0,03692218
Nebulosidade às 9h	-0,01423436	-0,04602176	0,1128058	-0,2558205	0,217427	-0,1876702	-0,6766421	-0,01184809
Nebulosidade às 15h	-0,03408618	-0,06025982	0,04614182	-0,2529099	0,1947896	-0,1929354	-0,700642	0,005461965
Temperatura às 9h	0,03110126	0,1711825	0,9080504	0,8931386	0,01971346	0,5902966	0,2871742	-0,02266212
Temperatura às 15h	0,02109265	0,192919	0,7287131	0,9846255	-0,06960503	0,6238116	0,4834359	-0,01240949
Precipitação hoje	-0,01399205	-0,02783464	0,05366698	-0,2159591	0,5521744	-0,2051409	-0,3274266	0,01264697
Precipitação amanhã em mm	-0,02101955	-0,004424006	0,1458612	-0,01320864	0,3176646	-0,04001303	-0,3002904	0,001511765
Precipitação amanhã	-0,01580212	-0,0278167	0,09409813	-0,1397219	0,2611479	-0,1202734	-0,4479867	0,01212511

Variáveis	Velocidade da rajada de vento	Direção dos ventos às 9h	Direção dos ventos às 15h	Velocidade dos ventos às 9h	Velocidade dos ventos às 15h	Umidade do ar às 9h	Umidade do ar às 15h	Pressão às 9h
Data								
Localização								
Temperatura Mínima								
Temperatura Máxima								
Precipitação								
Evaporação								
Claridade								
Direção da rajada de vento								
Velocidade da rajada de vento								
Direção dos ventos às 9h	-0,03851407							
Direção dos ventos às 15h	0,02608524	0,07060665						
Velocidade dos ventos às 9h	0,6133668	-0,1012571	-0,001053092					
Velocidade dos ventos às 15h	0,6921276	-0,02312548	-0,005395485	-0,001053092				
Umidade do ar às 9h	-0,2079255	0,0347072	-0,03130267	-0,251819	-0,1203381			
Umidade do ar às 15h	-0,04712559	0,02599321	-0,05008947	-0,06120305	0,02186552	0,6801844		
Pressão às 9h	-0,4353987	0,003836913	-0,05768326	-0,210526	-0,298989	0,1271878	-0,05831967	
Pressão às 15h	-0,3884183	0,01007253	-0,06227995	-0,1644786	-0,2581423	0,1839449	0,02975575	0,9619424
Nebulosidade às 9h	0,08495421	-0,006062237	-0,01439495	0,03450456	0,05915733	0,4337923	0,5079562	-
Nebulosidade às 15h	0,1263836	-0,007935874	0,000655142	0,06405072	0,03320572	0,3443706	0,5103528	0,1627539
Temperatura às 9h	0,1006613	-0,03869048	0,006765611	0,07318841	0,1278409	-0,4280343	-0,1485982	0,4560559
Temperatura às 15h	0,01198169	-0,04603269	0,02144605	-0,00491759	0,003905606	-0,4876455	-0,4943167	0,3244367
Precipitação hoje	0,1442036	0,01777464	0,002367983	0,08318401	0,0805668	0,3709535	0,3836265	0,1812785
Precipitação amanhã em mm	0,141358	-0,01116998	0,001123925	0,04211004	0,02971192	0,1803135	0,314344	0,1773826
Precipitação amanhã	0,2362182	-0,004060621	0,01015644	0,08727322	0,08781579	0,2615268	0,4494242	0,2567927

Variáveis	Pressão às 15h	Nebulosidade às 9h	Nebulosidade às 15h	Temperatura às 9h	Temperatura às 15h	Precipitação hoje	Precipitação amanhã em mm	Precipitação amanhã
Data								
Localização								
Temperatura Mínima								
Temperatura Máxima								
Precipitação								
Evaporação								
Claridade								
Direção da rajada de vento								
Velocidade da rajada de vento								
Direção dos ventos às 9h								
Direção dos ventos às 15h								
Velocidade dos ventos às 9h								
Velocidade dos ventos às 15h								
Umidade do ar às 9h								
Umidade do ar às 15h								
Pressão às 9h								
Pressão às 15h								
Nebulosidade às 9h	-0,0802447							
Nebulosidade às 15h	0,0996512	0,6133449						
Temperatura às 9h	0,5097164	-0,1007081	-0,102855					
Temperatura às 15h	0,4327508	-0,2735846	-0,2927362	0,8699243				
Precipitação hoje	0,0986683	0,2965029	0,2745728	-0,0895398	-0,2235089			
Precipitação amanhã em mm	0,1751337	0,2072552	0,2429907	0,07520903	-0,03715956	0,2247415		
Precipitação amanhã	0,2310826	0,3218178	0,3858118	-0,01069772	-0,1763032	0,3118783	0,4944745	

FONTE: O Autor (2019).

Adotando o valor de corte de 0,75 de correlação, quatro variáveis foram eliminadas: Temperatura Mínima, Pressão às 15h, Temperatura às 9h, Temperatura às 15h, pois apresentaram correlação superior ao valor de corte. A base de dados inicial terá 20 variáveis.

4.1 REDE NEURAL ARTIFICIAL PARA PREVISÃO DE OCORRÊNCIA DE CHUVA NO DIA SEGUINTE

A primeira RNA teve como finalidade prever se haverá ocorrência de precipitação no dia seguinte ou não. Os testes do número de neurônios na camada oculta foram realizados, bem como o cálculo do erro a cada iteração, conforme Tabela 3.

TABELA 3 – RESULTADOS RNA PARA PREVISÃO DE OCORRÊNCIA DE CHUVA NO DIA SEGUINTE.

Número de Neurônios na Camada Oculta	Erro	Número de Neurônios na Camada Oculta	Erro
1	2556	26	285
2	1187	27	372
3	2556	28	411
4	2556	29	319
5	1214	30	323
6	2556	31	1028
7	120	32	93
8	836	33	205
9	457	34	493
10	343	35	334
11	271	36	201
12	1120	37	292
13	305	38	265
14	321	39	785
15	281	40	436
16	281	41	432
17	2	42	994
18	647	43	266
19	283	44	107
20	267	45	508
21	244	46	315
22	213	47	0
23	878	48	1075
24	358	49	103
25	512	50	63

FONTE: O Autor (2019).

A rede que apresentou melhor desempenho possui 47 neurônios na camada oculta. O erro representa os dias do conjunto de teste que a rede previu que iria chover e na realidade não choveu, bem como o oposto, quando previu que não iria chover e na realidade choveu. Com 47 neurônios na camada oculta o valor de erro foi igual à zero para o conjunto de teste.

4.2 REDE NEURAL ARTIFICIAL PARA PREVISÃO EM MILIMETROS DE CHUVA NO DIA SEGUINTE

A segunda RNA utilizou 19 variáveis para previsão da quantidade, em milímetros, de chuva, pois a variável correspondente à chuva no dia seguinte foi desconsiderada para essa rede por não ser relevante. Com a realização dos testes e cálculos dos erros, os resultados obtidos são apresentados conforme Tabela 4.

TABELA 4 – RESULTADOS RNA PREVISÃO EM MILIMETROS DE CHUVA NO DIA SEGUINTE

	Número de Neurônios na Camada Oculta	Erro	Número de Neurônios na Camada Oculta	Erro
	1	8,818	26	8,390
	2	8,818	27	8,431
	3	8,818	28	8,233
	4	8,818	29	8,312
	5	8,818	30	8,455
	6	8,818	31	8,485
	7	8,390	32	8,913
	8	8,818	33	8,156
	9	8,317	34	8,353
	10	8,818	35	8,391
	11	8,818	36	8,077
	12	8,232	37	8,643
	13	8,615	38	9,082
	14	8,469	39	8,427
	15	8,409	40	8,497
	16	8,616	41	8,414
	17	8,428	42	8,265
	18	8,553	43	8,319
	19	8,313	44	8,291
	20	8,415	45	8,372
	21	8,394	46	8,528
	22	8,812	47	8,194
	23	8,138	48	8,889
	24	8,704	49	8,244
	25	8,199	50	8,278

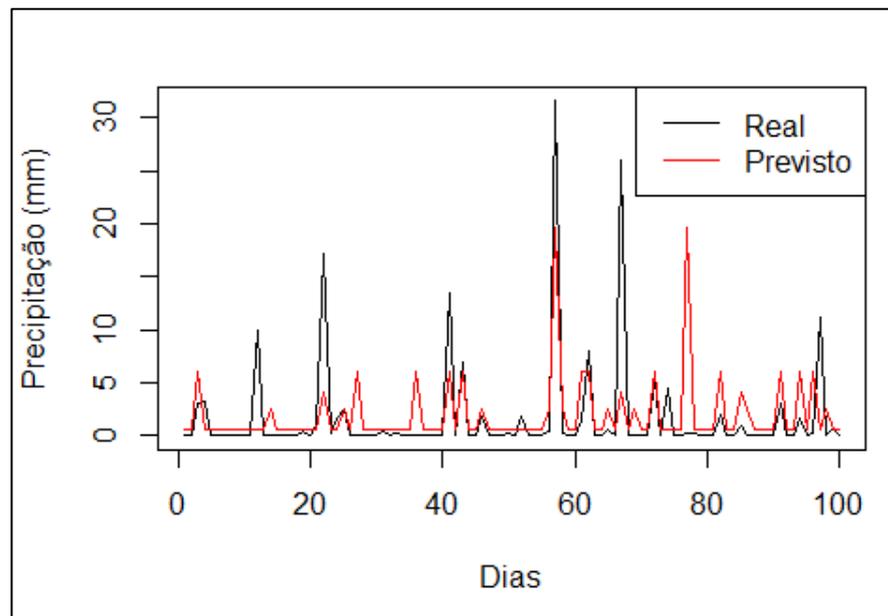
FONTE: O Autor (2019).

A melhor configuração de neurônios na camada oculta possui 36 neurônios, com a rede errando, em média, 8,077 mm em sua previsão para o conjunto de teste.

Comparando o resultado da rede neural com a média de chuva do conjunto de teste, com valor de 2,397 mm, percebe-se que houve uma diferença significativa com a rede tendo um erro de 3,36 vezes a média do conjunto de testes.

A FIGURA 3, também criada no software R, representa graficamente a quantidade real e prevista pela RNA de precipitação, 36 neurônios na camada oculta, para o intervalo de 100 primeiros dias do conjunto de testes, visando facilitar a visualização dos resultados.

FIGURA 3 – QUANTIDADE REAL E PREVISTA PELA RNA.



FONTE: O Autor (2019).

5 CONSIDERAÇÕES FINAIS

A aplicação do teste de Pearson para correlação foi importante para eliminar variáveis redundantes, diminuindo também o tempo de processamento dos cálculos.

As RNA tipo MLP utilizadas no trabalho obtiveram resultados satisfatórios para a primeira rede, quando comparados aos valores reais da base de dados, prevendo as chuvas para o dia seguinte sem erros para o conjunto de teste, com 47 neurônios na camada oculta.

Porém, a segunda rede com melhor configuração possui 36 neurônios na camada oculta, apresentou erro médio de 8,077 mm de chuva para o dia seguinte, um valor significativo quando comparado aos valores médios do conjunto de testes, de 2,397 mm.

O presente trabalho foi um estudo de caso com o objetivo de aplicar as RNA, com duas redes separadas, em previsão de ocorrência de chuvas e quantidade em milímetros, ambas para o dia seguinte. A mesma lógica e processo podem ser utilizados em outras áreas, com bases de dados apropriadas. Um exemplo de aplicação é uso em peças conformes e não conformes, com rede semelhante a primeira RNA, e como previsão de demanda de produtos, com parâmetros semelhantes a segunda RNA.

REFERÊNCIAS

BERGMEIR, C.; BENÍTEZ, J.M. Neural networks in R using the Stuttgart Neural Network Simulator: RSNNS. *Journal of Statistical Software*, v.46, p.1-26, 2012. Disponível em: <https://digibug.ugr.es/bitstream/handle/10481/39548/Bergmeir_RSNNS.pdf?sequence=1&isAllowed=y> Acesso em 5. jul. 2019.

BOCANEGRA, C. W. R. Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes. 108 f. Dissertação (Mestrado em Engenharia Civil) – Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, 2002. Disponível em: <https://www.researchgate.net/profile/Antonio_Nelson_Rodrigues_Da_Silva/publication/265189813_PROCEDIMENTOS_PARA_TORNAR MAIS EFETIVO O USO DAS REDES NEURAI S ARTIFICIAIS EM PLANEJAMENTO DE TRANSPORTES/links/5491786d0cf2d1800d892fc1.pdf> . Acesso em 10. set. 2019.

BRAGA, A., LUDERMIR, T., CARVALHO, A. *Redes Neurais Artificiais: Teoria e Aplicações*. São Paulo: LTC –Editora , 2000.

CASTRO, LN, FERRARI, DG. *Introdução à Mineração de Dados. Conceitos básicos, algoritmos e aplicações*. São Paulo: Saraiva, 2016.

DANTAS, D. et al. Uso de Redes Neurais Artificiais na previsão da precipitação de períodos chuvosos. *Revista Espinhaço | UFVJM*, [S.l.], p. 11-18, mar. 2017. ISSN 2317-0611. Disponível em: <<http://www.revistaespinhaco.com/index.php/journal/article/view/96>>. Acesso em 15 abr.2019.

DA SILVA, Oliveira Diego Armando Silva et al. Estimativa de volume de eucalipto empregando redes neurais artificiais. *Simpósio Latino-Americano sobre Manejo Florestal: 6 ed, Santa Maria*, p.319-324, 2015. Disponível em: <<https://www.ufsm.br/cursos/pos-graduacao/santa-maria/ppgef/eventos/6o-simposio-latino-americano-sobre-manejo-florestal/>>. Acesso em 20 out. 2019.

FERREIRA, C. C. Daily natural incoming flow to the reservoir Tucuruí using the technique of artificial neural networks. 2012. 117 f. Dissertação (Mestrado em Engenharia) - Universidade Federal de Goiás, Goiânia, 2012. Disponível em: <<http://repositorio.bc.ufg.br/tede/handle/tde/970>> Acesso em 15 out. 2019.

FIGUEIREDO, K. et al. Modelo de previsão de vazão com informação de precipitação utilizando redes neurais. *Revista Brasileira de Recursos Hídricos*, v. 12, n. 3, p. 69-82, 2007. Disponível em: <[http:// dx.doi.org/10.21168/rbrh.v12n3.p69-82](http://dx.doi.org/10.21168/rbrh.v12n3.p69-82).> Acesso em 12 mai. 2019.

HAYKIN, S., *Redes Neurais: Princípios e Práticas*, Ed. Bookman, 2001.

KAGGLE, 2019. Disponível em: < <https://www.kaggle.com/jsphyg/weather-dataset-rattle-package>> Acesso em 06 mai. 2019.

KOVÁCS, Z. L. Redes neurais artificiais: fundamentos e aplicações 4 ed. São Paulo: Editora Livraria da Física, 2006.

LIMA, I.; PINHEIRO, C.; OLIVEIRA, F. S. Inteligência artificial São Paulo: Elsevier Brasil, 2014.

MAGONE A., MAZALI T. Industria 4.0. Uomini e macchine nella fabbrica digitale. Guerini e associati: Milano, 2016.

MATHWORLD. Disponível em: <<http://mathworld.wolfram.com/SigmoidFunction.html>>. Acesso em 20 dez. 2019.

MOREIRA, M. C. et al . Desenvolvimento e análise de uma rede neural artificial para estimativa da erosividade da chuva para o Estado de São Paulo. Rev. Bras. Ciênc. Solo, Viçosa , v. 30, n. 6, p. 1069-1076, Dez. 2006 . Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-06832006000600016&lng=en&nrm=iso>. Acesso em 10 mai. 2019.

NORVIG,P., RUSSELL,S. Inteligência Artificial. 3 ed São Paulo: Elsevier Brasil, 2014.

POPKOVA, E. G., RAGULINA, Y. V., BOGOVIZ, A. V.. Industry 4.0: Industrial revolution of the 21st century. In *Studies in Systems, Decision and Control*. Berlin: Springer, 2019.

QUILES, M. G. Sistema de Visão Baseado em Redes Neurais para o Controle de Robôs Móveis. 2004. Dissertação (Mestrado em Ciência da Computação e Matemática Computacional) - Universidade de São Paulo. São Paulo. 2004. Disponível em: <https://teses.usp.br/teses/disponiveis/55/55134/tde-18082016-155035/publico/MarcosGonvalvesQuiles_ME.pdf> Acesso em 10 nov. 2019.

RÊGO, A. S. Predição de parâmetros de qualidade do biodiesel utilizando redes neurais artificiais. 2013. 119 f. Dissertação (Mestrado em Engenharia) - Universidade Federal do Maranhão, São Luís, 2013. Disponível em: <<https://tede2.ufma.br/jspui/bitstream/tede/507/1/Dissertacao%20Adriano.pdf>> Acesso em 10 set. 2019.

REZENDE, S. O. Sistemas inteligentes: fundamentos e aplicações Barueri: Manole, 2005.

YEGNANARAYANA,B. Artificial Neural Networks, India, New Delhi:Prentice-Hall India, 2006.