

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE PESQUISAS HIDRÁULICAS
CURSO DE GRADUAÇÃO EM ENGENHARIA AMBIENTAL

ANGÉLICA DE PAOLI SCHMIDT

ESTIMATIVA DA CURVA-CHAVE COM REDES NEURAS ARTIFICIAIS:
ESTUDO DE CASO - ARROIO TABOÃO

Porto Alegre

2022

ANGÉLICA DE PAOLI SCHMIDT

**ESTIMATIVA DA CURVA-CHAVE COM REDES NEURAIS ARTIFICIAIS:
ESTUDO DE CASO - ARROIO TABOÃO**

Trabalho de Conclusão apresentado ao Curso de Engenharia Ambiental da Universidade Federal do Rio Grande do Sul como parte de exigência para a obtenção do título de Engenheira Ambiental.

Orientadores:

Prof.^a. Dra. Nilza Maria dos Reis Castro

Prof. Dr. Olavo Correa Pedrollo

Porto Alegre

2022

CIP - Catalogação na Publicação

de Paoli Schmidt, Angélica
Estimativa da curva-chave com redes neurais
artificiais: estudo de caso - arroio Taboão / Angélica
de Paoli Schmidt. -- 2022.
49 f.
Orientadora: Dra. Nilza Maria dos Reis Castro.

Coorientador: Dr. Olavo Correa Pedrollo.

Trabalho de conclusão de curso (Graduação) --
Universidade Federal do Rio Grande do Sul, Instituto
de Pesquisas Hidráulicas, Curso de Engenharia
Ambiental, Porto Alegre, BR-RS, 2022.

1. redes neurais artificiais. 2. curva-chave. 3.
cota. 4. hidrologia. 5. vazão. I. dos Reis Castro,
Dra. Nilza Maria, orient. II. Correa Pedrollo, Dr.
Olavo, coorient. III. Título.

ANGÉLICA DE PAOLI SCHMIDT

**ESTIMATIVA DA CURVA-CHAVE COM REDES NEURAS ARTIFICIAIS:
ESTUDO DE CASO - ARROIO TABOÃO**

Trabalho de Conclusão de Curso em Engenharia
Ambiental da Universidade Federal do Rio Grande
do Sul defendido e aprovado em
____/____/____ pela Comissão avaliadora
constituída por:

BANCA EXAMINADORA

Professora Orientadora Dr^a Nilza Maria dos Reis Castro
Departamento de Obras Hidráulicas
Instituto de Pesquisas Hidráulicas – IPH

Professor Coorientador Dr. Olavo Correa Pedrollo
Departamento de Obras Hidráulicas
Instituto de Pesquisas Hidráulicas – IPH

Professora Dr^a Vanessa Sari

Universidade Federal de Santa Maria – UFSM

Msc Juliana Andrade Campos

Doutoranda em Recursos Hídricos e Saneamento Ambiental – IPH

Agradeço à Universidade Pública, minha família, meus amigos, meus orientadores e àquelas pessoas que passaram por mim durante essa trajetória. Agradeço também todas as oportunidades vivenciadas durante a minha graduação nesta Universidade de qualidade. Foi a melhor escolha que fiz na vida até o momento.

RESUMO

Atualmente enfrentamos no Brasil uma crise devido à ocorrência de chuvas inferiores ao necessário implicando em falta de água em atividades essenciais como: geração de energia, saneamento básico, agricultura, entre outros. Por outro lado, chuvas intensas têm ocorrido em locais vulneráveis causando grandes enchentes. Nessas condições, estudos das variáveis hidrológicas são necessários para buscar informações e proferir medidas para monitorar e garantir o uso desse bem comum, que é a água. Buscar informações sobre a dinâmica do ciclo hidrológico, suas limitações e abundância, possibilita aos agentes governamentais tomarem decisões para preservar e assegurar o abastecimento de água à população, além de permitir o planejamento de prevenção de enchentes. As variáveis hidrológicas estudadas neste trabalho são o nível do rio (cota) e a vazão. Esta pesquisa foi aplicada na bacia do arroio Taboão, que é uma sub-bacia do rio Potiribu, localizada no noroeste do estado do Rio Grande do Sul. A partir de dados de cota e de vazão medidos entre 2001 e 2020, foram utilizadas redes neurais artificiais (RNAs) para estimar vazões a partir de dados de níveis d'água, e comparar com três metodologias tradicionais de curva-chave: linear, potencial e polinomial. As RNAs consistem no aprendizado de máquina (*machine learning*), amplamente aceito e utilizado ao redor do mundo, pela qual é possível modelar fenômenos e alcançar objetivos a partir de um conjunto de dados conhecidos. A RNA foi treinada por meio do algoritmo retropropagativo, e o superajustamento foi evitado por meio de validação cruzada. As estatísticas de desempenho e os gráficos plotados indicam que as RNAs fazem uma melhor aproximação com os dados observados, em relação às outras três equações de curva-chave. Os resultados obtidos mostram um menor erro médio absoluto para a RNA no valor de 0,322; 0,355 para a linear; 0,343 para a potencial e 0,329 para a polinomial. Coeficiente de NS para a RNA e polinomial no valor de 0,985 e 0,984 para a linear e potencial. O coeficiente NS foi praticamente igual para todas as curvas-chaves testadas e também para a RNA. A análise gráfica com as três equações e com a RNA, mostrou que no extremo inferior para cotas baixas <32 cm e <34 cm as equações polinomial e linear resultaram valores negativos para as vazões. A equação potencial não resultou em valores negativos para cotas baixas, porém teve um percurso que distanciou mais do comportamento das medições e das outras curvas-chaves. Com essas informações, concluiu-se que a RNA descreveu melhor tanto graficamente como resultou em valores mais baixos dos erros analisados. Logo, recomenda-se o uso da RNA para a elaboração da curva-chave.

Palavras-chaves: hidrologia; cota; vazão; monitoramento.

ABSTRACT

We are currently facing a crisis in Brazil due to the occurrence of less than necessary rainfall, resulting in a lack of water in essential activities such as: energy generation, basic sanitation, agriculture, among others. On the other hand, heavy rains have occurred in vulnerable locations causing massive flooding. Under these conditions, studies of hydrological variables are necessary to seek information and take measures to monitor and guarantee the use of this common good, which is water. Searching for information about the dynamics of the hydrological cycle, its limitations and abundance, enables government agents to make decisions to preserve and ensure the population's water supply, in addition to allowing flood prevention planning. The hydrological variables studied in this work are the river level (elevation) and the flow. This research was applied in the Taboão stream basin, which is a sub-basin of the Potiribu River, located in the northwest of the state of Rio Grande do Sul. From elevation and flow data measured between 2001 and 2020, artificial neural networks (ANNs) were used to estimate flows from river stage, and compare with three traditional rating curve methodologies: linear, potential and polynomial. ANNs consist of machine learning, widely accepted and used around the world, through which it is possible to model phenomena and achieve goals from a set of known data. The ANN was trained using the back-propagation algorithm, and overfitting was avoided through cross-validation. The performance statistics and plotted graphs indicate that the ANNs make a better approximation to the observed data, in relation to the other three rating curve equations. The results obtained show a lower mean absolute error for the ANN in the value of 0.322; 0.355 for linear; 0.343 for the potential and 0.329 for the polynomial. NS coefficient for ANN and polynomial in the value of 0.985 and 0.984 for linear and potential. The NS coefficient was practically the same for all the rating curves tested and also for the ANN. The graphical analysis with the three equations and the ANN showed that at the lower end for elevations <32 cm and <34 cm the polynomial and linear equations resulted in negative values for the flows. The potential equation did not result in negative values for low elevations, but had a path that distanced more from the behavior of the measurements and the other key curves. With this information, it is concluded that the ANN described better graphically and resulted in lower values of the errors analyzed. Therefore, it is recommended to use the ANN for the elaboration of the rating curve.

Keywords: hydrology; quota; flow rate; monitoring.

LISTA DE FIGURAS

Figura 1 - Representação de um neurônio biológico.....	17
Figura 2 - Modelo da rede neural artificial.....	18
Figura 3 - Funções de ativação e suas derivadas.....	19
Figura 4 - Localização da bacia hidrográfica de Taboão	27
Figura 5 - Temperatura máximas e mínimas das médias mensais	29
Figura 6 - Gráfico de precipitação médias mensais e umidade relativa do ar média mensal..	30
Figura 7 - Posto fluviométrico do arroio Taboão (a-instalações da tubulação, linígrafo, caixa com loggers e rampa de acesso, b-sistema de cabos teleféricos e roldanas para medições de vazão com cotas altas c-abrigo para efetuar as medições,).	31
Figura 8 - Perfil transversal do arroio Taboão	32
Figura 9 - Fluxograma da comparação da curva-chave com RNA e equações convencionais	34
Figura 10 - Gráfico da simulação de quantidade de neurônios na camada interna da RNA ...	37
Figura 11 - Configuração da rede neural resultante: na camada de entrada a variável cota, dois neurônios na camada interna e camada de saída a variável descarga (vazão).....	38
Figura 12 - Gráfico das equações convencionais e RNA	40

LISTA DE TABELAS

Tabela 1 – Estatísticas de desempenho da RNA	38
Tabela 2 – Estatísticas de desempenho das equações convencionais	39
Tabela 3 - Comparação dos indicadores de desempenho da curva-chave convencional e RNA.	39
Tabela 4 – Curva-chave gerada pela RNA (cota em metros e vazão em m ³ /s).....	48

LISTA DE SIGLAS

% E05	Quantil 5% dos Erros
% E50	Quantil 50% dos Erros
% E95	Quantil 95% dos Erros
ADCP	Acoustic Doppler Current Profiler
ADELAINÉ	Adaptive Linear Element
CPRM	Companhia de Pesquisa de Recursos Minerais
CSS	Concentração de Sedimentos em Suspensão
EAM	Erro Absoluto Médio
EM	Erro Médio
ER	Erro Relativo Absoluto
EUA	Estados Unidos da América
EWMA	Exponentially Weighted Moving Average
FEPAM	Fundação Estadual de Proteção Ambiental Henrique Luis Roessler -RS
INMET	Instituto Nacional de Meteorologia
IPH	Instituto de Pesquisas Hidráulicas
MPL	<i>Multilayer Perceptron</i> (Redes Perceptron Multicamadas)
NS	Coefficiente de Nash-Sutcliffe
ONS	Operador Nacional do Sistema Elétrico
PB	Paraíba
RMSE	Root Mean Square Deviation
RN	Referência de Nível
RNA	Rede Neural Artificial
RNAs	Redes Neurais Artificiais
RS	Rio Grande do Sul
SMAP	Soil Moisture Accounting Procedure
UFRGS	Universidade Federal do Rio Grande do Sul

SUMÁRIO

1	INTRODUÇÃO	12
1.1	OBJETIVOS	13
1.1.1	Objetivo Geral	13
1.1.2	Objetivos Específicos	13
2	REFERENCIAL TEÓRICO	15
2.1	CURVA-CHAVE	15
2.2	REDES NEURAIS ARTIFICIAIS.....	16
2.3	ESTATÍSTICAS DE DESEMPENHO.....	22
2.4	ESTUDOS DE APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS (RNAS) PARA DETERMINAÇÃO DE VARIÁVEIS HIDROLÓGICAS.....	23
4	MATERIAIS E MÉTODOS.....	27
4.1	CARACTERIZAÇÃO DA ÁREA DE ESTUDO.....	27
4.1.1	GEOLOGIA, RELEVO E SOLO.....	28
4.1.2	CLIMA E PRECIPITAÇÃO.....	29
4.2	ESTAÇÃO FLUVIOMÉTRICA DO ARROIO TABOÃO	30
4.3	DETERMINAÇÃO DA CURVA-CHAVE POR AJUSTES TRADICIONAIS.....	35
4.4	DETERMINAÇÃO DA CURVA-CHAVE POR AJUSTES RNA	35
5	RESULTADOS E DISCUSSÕES	37
5.1	AJUSTES DO MODELO: RNA	38
5.2	AJUSTES DOS MODELOS: LINEAR, POTENCIAL E POLINOMIAL.....	38
5.3	COMPARAÇÃO DOS MODELOS AJUSTADOS.....	39
6	CONSIDERAÇÕES FINAIS.....	42
7	REFERÊNCIAS	44
8	ANEXO.....	48

1 INTRODUÇÃO

Em 2021, o ministro de Minas e Energia do Brasil relatou o enfrentamento da pior seca dos últimos 91 anos. Os volumes de chuvas inferiores nas bacias hidrográficas comprometeram a matriz energética brasileira, que, na maior parte, é provida de energia hidrelétrica. Diversas práticas agrícolas e atividades industriais também foram afetadas, pois ambas têm uma demanda alta de água. Outra consequência da crise hídrica é o impacto social: aumento da conta de luz, dos preços de alimentos, e do desemprego no período da pandemia.

A Constituição Federal de 1988 cita que compete à União planejar e promover a defesa permanente contra as calamidades públicas, especialmente as secas e as inundações (BRASIL, 1988). Portanto, é importante o estudo de variáveis hidrológicas, principalmente a estimativa da vazão dos rios, para propiciar melhor planejamento, monitoramento e preservação dos recursos naturais, além de servir como orientação para planos governamentais.

O monitoramento fluviométrico dos rios é importante para uma melhor gestão e gerenciamento dos recursos hídricos. O conhecimento da vazão de um rio ao longo do tempo é fundamental para diversas atividades humanas, tais como operações de reservatórios de barragens, atividades de irrigação, abastecimento de água, etc. No entanto, a estimativa direta da vazão de um rio é um procedimento que demanda recursos humanos (disponibilidade de equipe) e financeiros (medir vazão com molinete ou com ADCP todos os dias é inviável na maior parte dos casos), e acaba sendo realizado algumas vezes, mas não diariamente. Na maior parte das vezes, as vazões são estimadas indiretamente, a partir de dados de nível d'água que são facilmente obtidos por meio de réguas limimétricas. Estas estimativas indiretas são chamadas de curva-chaves.

A curva-chave é o termo empregado na hidrologia para designar a relação entre a cota (nível d'água) e a vazão que escoar em uma dada seção transversal de um curso d'água. Também conhecida como curva de calibragem, cota-vazão e cota-descarga, permite o cálculo indireto da vazão na referida seção a partir da leitura da cota em um dado momento (SEFIONE, 2002).

Dentre os vários modelos disponíveis atualmente, o modelo de Rede Neural Artificial (RNA) tem sido amplamente aceito como forma potencialmente útil de se modelar sistemas não-lineares complexos com grande quantidade de dados. Esses modelos são particularmente úteis em situações nas quais as relações dos processos físicos ainda não são completamente compreendidas. Os modelos de RNAs podem, ainda, substituir os modelos matemáticos e estatísticos convencionais ou se associar a eles (SOUSA *et al.*, 2019).

Entre os principais benefícios das RNAs estão a “não-linearidade” e a “adaptabilidade e aprendizagem” (GORODETSKAYA, 2018). Uma RNA é não-linear se esta for constituída de neurônios artificiais também não-lineares. Esta é uma característica importante, pois a maioria dos sistemas físicos responsáveis pela geração do mapeamento entre os sinais de entrada e saída desejada são não-lineares. Já a adaptabilidade e aprendizagem é importante, pois dependendo da mudança de um ambiente, faz-se necessário um novo treinamento da RNA com aplicação de novos exemplos explorando sua capacidade de se adaptar.

De fato, desde o início dos anos 90, as RNAs têm sido usadas com sucesso em áreas relacionadas à hidrologia, como modelagem de chuva-vazão, previsão de corrente de fluxo, modelagem de águas subterrâneas, qualidade da água, política de gestão da água, previsão de precipitação e operações de reservatórios (ASCE, 2000).

Neste trabalho, pretende-se simular a rede neural artificial para estimar dados de vazão a partir de dados de nível d'água (cota) e comparar com estimativas realizadas com metodologias tradicionais de curva-chave.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Analisar se uma rede neural artificial (RNA) apresenta melhores resultados na aproximação de uma curva-chave em relação às três equações convencionais mais utilizadas: linear, potencial e polinomial.

1.1.2 Objetivos Específicos

Os objetivos específicos dessa pesquisa são:

1. Desenvolver uma RNA com uso do programa *Octave* (*software* livre), determinando a melhor arquitetura de rede encontrada e otimizar o modelo visando a precisão sem cair no problema do superajustamento;
2. Avaliar a performance do modelo da RNA e das três equações convencionais através de estatísticas de desempenho apropriadas;

3. Comparar graficamente a aproximação entre os dados calculados e os observados RNA e pelas equações convencionais ajustadas.

2 REFERENCIAL TEÓRICO

2.1 CURVA-CHAVE

Com a curva-chave é possível transformar medições de cota, que são relativamente pouco onerosas, em medições de vazão. As medições de cota, por serem fáceis de serem executadas, podem ser realizadas com frequência maior, bastando para isso um observador, que lê manualmente o nível da água do rio em uma régua instalada no local do posto fluviométrico, ou um equipamento automático de medição de nível (COLLISCHONN e DORNELLES, 2013).

A equação é ajustada aos dados de medição de vazão. Essa curva pode ser ajustada manualmente, de forma gráfica, ou podem ser utilizadas equações de ajuste, através de regressão. Normalmente são utilizadas equações do tipo potência, como a equação 1:

$$Q = a \times (h - h_0)^b \quad \text{equação 1}$$

Onde Q é a vazão; h é a cota; h_0 é a cota quando a vazão é zero; a e b são parâmetros ajustados por um critério, como erros mínimos quadráticos (COLLISCHONN; DORNELLES, 2013).

O estudo da relação cota-descarga, caracterizada por um período de validade e uma faixa de amplitude entre as cotas mínimas e máximas observadas, é realizado a partir de uma série de dados de medição de níveis d'água, abrangendo a maior amplitude de cotas possível de ser monitorada. A partir daí o hidrólogo procura definir a relação $Q(h)$ que poderá ser simples ou até impossível de ser determinada (JACCON, 1989).

Na extrapolação de uma curva-chave sempre existirá incerteza associada, principalmente na parte superior da curva. Isso ocorre porque, geralmente, nessa parte existem poucos dados disponíveis, pois é muito difícil e perigoso medir grandes vazões, pois geralmente acontecem durante eventos de chuva. Por outro lado, quando existem bastante dados para as grandes vazões, o que se observa, em geral, é uma grande dispersão, que usualmente é ocasionada pela dificuldade da medição (GRISON, 2009).

Obviamente, para se ter uma curva-chave válida é necessário possuir um monitoramento contínuo da seção transversal em análise e ainda ter várias medidas de vazão abrangendo diferentes níveis d'água, inclusive medidas de cheias e cotas mínimas, para desta forma prolongar a validade dos dados, ou seja, aumentar o domínio da curva-chave desenvolvida (FUNKE, 2018).

As equações da curva-chave comumente utilizadas são:

- Linear: equação 2

$$Q = a + bh$$
- Potencial: equação 3

$$Q = a \times (h - h_0)^b$$
- Polinomial dos tipos quadráticas e cúbicas: equação 4

$$Q = a_0 + a_1 \times h + a_2 \times h^2 + \dots + a_n h^n$$

Na ausência de medições em cotas altas ou baixas, se impõe uma extrapolação da curva em suas extremidades (JACCON, 1989). Esta extrapolação depende do conhecimento da forma da seção dos níveis de extrapolação, ou da aceitação de hipóteses sobre o comportamento da curva na zona extrapolada, não sendo objeto deste estudo.


2.2 REDES NEURAIS ARTIFICIAIS

Os estudos das RNAs foram iniciados em 1943 pelo neurofisiologista Warren McCulloch e o matemático Walter Pitts. Em seu artigo “*A Logical Calculus of Ideas Immanent in Nervous Activity*” os autores apresentaram um modelo simplificado do funcionamento do neurônio biológico, baseado em entradas e saídas binárias e em limiares de ativação, sugerindo a possibilidade de uma rede neural artificial, embora sem uma arquitetura definida ou um processo de ajuste de pesos.

O sistema de neurônios pode ser resumido em três partes principais: dendritos, corpo e axônio (Figura 1):

- I. Dendritos: são os receptores, recebem as entradas;
- II. Corpo: processa a informação que recebe, isto é, função (g) que agrega as entradas;
- III. Axônio: transmite o sinal, podendo ou não ser ativado, função (f) que decide a ativação em concordância com a saída de (g) (define um limiar se o neurônio irá ativar).

Figura 1 - Representação de um neurônio biológico



Fonte: Deep Learning Book

O modelo Perceptron de Rosenblatt (1947) foi a primeira estrutura de neurônios proposta (com uma única camada), compreendendo uma rede neural funcional, com uma técnica de treinamento, porém, limitado a entradas e saídas binárias, o que reduzia muito a sua aplicação.

Já o modelo de Widrow e Hoff (1960), embora mantendo a mesma estrutura de Perceptron, admitia entradas e saídas reais (não limitadas a valores binários). Para isso, introduziu um método de treinamento do tipo gradiente-descendente, chamado de Regra Delta. A versão linear, um caso particular, foi chamada de ADALINE e, apesar de ser linear, apresentava grande potencial por ser adaptativa, ou seja, cada nova instância amostral, durante a aplicação, era utilizada também para a atualização do treinamento. Porém, mesmo com estes desenvolvimentos, esta rede não era capaz de aproximar funções não lineares.

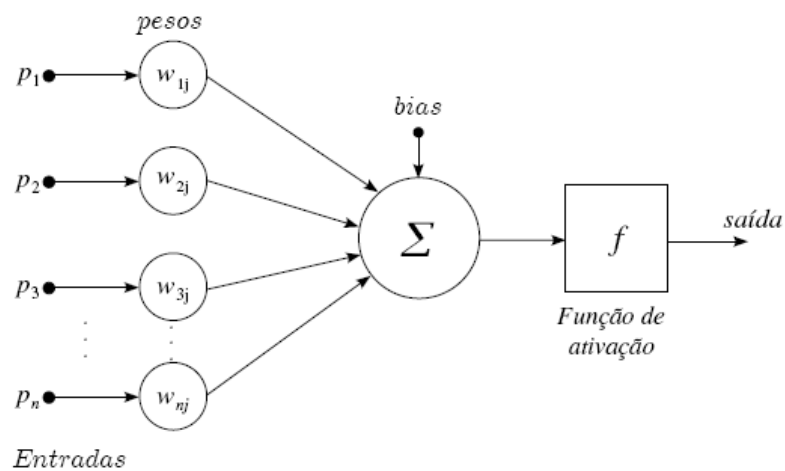
Uma RNA é, portanto, um modelo de aprendizado de máquina inspirado nas redes de neurônios biológicos encontrados em nossos cérebros (GÉRON, 2019).

Os fundamentos das RNAs são o modelo de um neurônio, a topologia da rede e os paradigmas de aprendizagem (RAUBER, 1998). A formação das conexões entre as células e algumas considerações sobre como se concebe teoricamente o funcionamento matemático, ajudam a entender as bases da aprendizagem de máquina e das redes neurais. (Deep Learning Book Brasil, 2021). As RNAs podem ser descritas como uma rede de neurônios interconectados, às vezes chamados nós. (DAWSON, 2001).

Uma rede neural artificial (RNA) é composta por um grande número de unidades interconectadas de processamento (nós), arranjadas em uma camada de entrada (*Input Layer*), em uma camada de saída (*Output Layer* ou *Grossberg Layer*), e em uma ou mais camadas ocultas (*Hidden Layer*). Cada camada consiste de um ou mais nós.

Matsunaga (2012) representa o modelo artificial do neurônio sendo uma generalização do modelo de McCulloch e Pitts. Esse modelo inclui um sinal adicional *bias* (b) que favorece ou limita a possibilidade de ativação do neurônio. O processo sináptico é representado pelos pesos (w) que amplificam cada um dos sinais recebidos. A chamada função de ativação (f) modela a forma como o neurônio responde ao nível de excitação, limitando e definindo a saída da rede neural. A Figura 2 representa esse processo.

Figura 2 - Modelo da rede neural artificial



Fonte: Curso de redes neurais utilizando o *Matlab*

Bravo *et al.* (2008) definem a unidade de processamento de RNAs, o neurônio matemático, pela equação 5:

$$S = F(\sum_{i=1}^n w_i \times E_i + b) \quad \text{equação 5}$$

Onde:

S = Valor de resposta do neurônio

F = Função de ativação

w_i = Pesos sinápticos

E_i = Valores de entradas que são processadas no neurônio

b = Tendência ou *bias* do valor e saída


O tipo de rede neural MLP (*Multilayer Perceptron*) segundo Gorodetskaya (2018) é formada por um conjunto de neurônios (ou nós), que formam as camadas de entrada, intermediária e de saída da rede. Um simples neurônio processa diversas entradas aplicando uma função de ativação em uma combinação linear de entradas.

As funções de ativação podem ser divididas em dois grupos principais, isto é, funções parcialmente diferenciáveis e funções totalmente diferenciáveis, considerando-se para tanto todo o domínio de definição das mesmas (SILVA *et al.*, 2016). As funções de ativação devem ser diferenciáveis.

A Figura 3 representa algumas das funções de ativação que podem ser usadas em redes neurais:

- *Step* (degrau bipolar)
- *Sigmoid* (ou logística): $\sigma(z) = 1/(1 + \exp(-z))$
- *Tanh* (tangente hiperbólica)
- *Relu*

Figura 3 - Funções de ativação e suas derivadas



Fonte: Hands-on Machine Learning with Scikit-Learn, Keras e TensorFlow.

A função de ativação mais tradicional é a função sigmoide unipolar, com saída no intervalo $[0,1]$ (PEDROLLO, 2017).

A Regra Delta, Widrow e Hoff (1960), calcula, em passos sucessivos, os pesos sinápticos da RNA, a partir dos erros conhecidos para cada neurônio. Os erros, para redes de uma camada (Perceptrons) resultam, simplesmente, das diferenças entre os valores conhecidos nas saídas, e os valores calculados. O algoritmo procura minimizar o erro obtido pela rede por meio do método do gradiente descendente.

A regra de propagação é dada pelo produto interno das entradas ponderadas pelos pesos com adição do termo *bias* e, a saída da camada anterior é a entrada da camada atual (HAYKIN, 2001). Nas camadas intermediárias, porém, estes eram considerados praticamente impossíveis de serem conhecidos, até que Rumelhart et al (1986) apresentaram o recurso de obter estes erros com a retropropagação das saídas na última camada, sucessivamente para todas as camadas anteriores. Sendo possível treinar as redes neurais com camadas intermediárias, resultando no modelo de RNA do tipo MLP (Redes Perceptron Multicamadas).

O cálculo da rede neural e seus erros na camada interna e na camada de saída são, respectivamente:

$$e_s = (t - s) \quad \text{equação 6}$$

e_s = erros dos neurônios da camada da saída

t = valores objetivo

s = valores calculados

$$e_h = \sum_s e_s \times \delta_k \times \omega_s \quad \text{equação 7}$$

e_h = erros dos neurônios da camada interna

e_s = erros dos neurônios da camada da saída

δ_k = derivadas da função de ativação na camada de saída

ω_s = pesos sinápticos na camada de saída

Essa equação é utilizada tanto na camada intermediária (ω_h) como na camada de saída (ω_s). Os pesos sinápticos são inicializados aleatoriamente.

$$\omega_{k+1} = \omega_k + \tau \times e_k \times \delta_k \times P_k \quad \text{equação 8}$$

ω_k = pesos sinápticos atuais

τ = taxa de aprendizado

e_k = erros de saída na camada k

δ_k = derivadas da função de ativação dos neurônios da camada k

P_k = entrada dos neurônios da camada k

Conforme o teorema da existência de Hecht- Nilsen (1987), “dada uma relação contínua $r: [0,1]^n \rightarrow \mathbb{R}^n$, existe uma rede neural artificial, com uma única camada interna e com $2n + 1$ neurônios nesta camada, a qual pode aproximá-la exatamente”.

Hornik (1991) aborda ainda o Teorema da Aproximação Universal: “dada uma relação mensurável $r: \mathbb{R}^n \rightarrow \mathbb{R}^m$, existe uma rede neural, com uma camada interna, a qual pode, desde que com um número compatível de neurônios artificiais nesta camada e adequadamente treinada, aproximá-la com qualquer precisão desejada”.

Justamente essa grande capacidade de aproximação pode resultar em um fenômeno chamado superajustamento. O superajustamento ocorre quando o número de neurônios na camada intermediária for excessivo ou quando o número de ciclos executado é muito grande, assim a rede é excessivamente treinada, prejudicando a sua capacidade de generalização.

Para determinar a parada do treinamento da rede e evitar o superajustamento, utiliza-se a técnica de validação cruzada. Neste processo, os erros do treinamento seguem diminuindo, enquanto os erros da série de validação, a partir de um determinado ciclo, tornam a crescer. Este é o instante em que o limiar é atingido, a partir do qual a capacidade de generalização fica comprometida, havendo, portanto, a interrupção do treinamento (HECHT- NIELSEN, 1990).

O controle do superajustamento também é realizado pela limitação da complexidade do modelo (número de neurônios nas camadas internas), ou pela interrupção oportuna do treinamento resultante de condições suficientes de finalização, que resultam da análise dos efeitos sobre uma amostra diferente da utilizada no treinamento (SARI, 2017). Não se deve confundir a amostragem de validação, utilizada neste procedimento, com a amostragem de verificação final da capacidade de generalização, que não deve ter participado de nenhum procedimento anterior (PEDROLLO, 2017).

Sari *et al.* (2017) apresenta o paradigma da pesquisa da complexidade ideal, definida como a complexidade mínima que, sendo controlado o superajustamento, ainda apresenta, na amostragem de validação, pelo menos o mesmo desempenho que uma rede neural propositadamente mais complexa. Em Lucchese *et al.* (2020) este paradigma é ampliado, pela admissão de aleatoriedade nos índices de desempenho utilizados, que recomenda uma análise gráfica para a tomada de decisão, com base na identificação do patamar aproximado de desempenho das complexidades suficientes, e, conseqüentemente, do limiar procurado.

Os sistemas de aprendizado de máquina podem ser classificados de acordo com a quantidade e o tipo de supervisão que recebem durante o treinamento. Existem quatro categorias

principais: aprendizagem supervisionado, aprendizagem não supervisionada, aprendizagem semissupervisionada e aprendizagem por reforço (GÉRON, 2019).

Fontana (2020) descreve as diferenças dos tipos de aprendizados: os algoritmos de aprendizagem supervisionada relacionam uma saída com uma entrada com base em dados rotulados. Neste caso, o usuário alimenta ao algoritmo pares de entradas e saídas conhecidos, normalmente na forma de vetores, o algoritmo determina uma forma de prever qual saída com base em uma entrada informada. No caso dos algoritmos de aprendizagem não-supervisionada, o algoritmo busca padrões e similaridades entre os dados, permitindo identificar grupos de itens similares ou similaridade de itens novos com grupos já definidos. Em alguns casos, pode-se treinar a rede com um conjunto de dados onde somente parte destes dados é rotulada, normalmente, somente uma pequena fração dos dados recebe um rótulo, porém isto tende a melhorar significativamente o desempenho dos algoritmos de aprendizagem não supervisionada. Esta abordagem híbrida é normalmente chamada de aprendizagem semissupervisionada. E por fim, o aprendizado por reforço, um agente realiza uma ação (dentro uma série de ações possíveis) em um ambiente e recebe uma recompensa de acordo com o resultado dessa ação. O agente é a rede que está sendo treinada.

2.3 ESTATÍSTICAS DE DESEMPENHO

As principais equações de desempenho utilizadas encontram-se descritas a seguir:

O coeficiente de eficiência de Nash-Sutcliffe (1970) é uma métrica adimensional tradicionalmente utilizada para a avaliação de modelos hidrológicos. Análogo ao coeficiente de determinação, compara-se o erro quadrado dos erros da série modelada com os desvios observados em relação à média histórica, expressando a proporção da variância dos dados observados que são representados pelo modelo (LANNA e INDURSKY, 1983).

$$NS = 1 - \frac{\sum(Y_0 - Y_C)^2}{\sum(Y_0 - \bar{Y})^2} \quad \text{equação 9}$$

Y_0 = variável observada

Y_C = variável calculada

\bar{Y} = média da variável observada

Além do coeficiente de Nash-Sutcliffe também serão utilizadas as estatísticas de erros representativos (dados em m³/s):

- Erro absoluto médio (EAM): $EAM = \frac{1}{N} \sum_N |Y_0 - Y_C|$ equação 10
- Em = Erro Médio
- % E05 = Quantil 0,05 dos erros
- % E50 = Quantil 0,50 dos erros (mediana)
- % E95 = Quantil 0,95 dos erros

2.4 ESTUDOS DE APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS (RNAs) PARA DETERMINAÇÃO DE VARIÁVEIS HIDROLÓGICAS

As redes neurais podem ser aplicadas em inúmeras simulações em todos os campos de conhecimento. Na hidrologia, por exemplo, podem ser utilizadas para preencher dados de falhas, como realizado por Depiné (2014), que testou uma metodologia utilizando as RNAs para preenchimento de falhas em séries horárias com dados de precipitação na bacia do arroio Taboão, Rio Grande do Sul.

Os resultados do estudo realizado pela autora mostram um coeficiente de Nash-Sutcliffe com melhor desempenho ($>0,9$) quando se utilizou séries curtas para treinamento (de 300 a 850 valores) e, apresentando um NS inferior a 0,85 quando foram utilizadas séries longas. Além disso, a escolha da série de treinamento na mesma estação climática que os dados a serem preenchidos mostrou-se o fator mais importante para a reprodução adequada das chuvas horárias (Depiné, 2014).

Na previsão de variáveis hidrológicas, SOUSA (2010) modelou a relação não-linear entre chuva e vazão na bacia do Rio Piancó, semiárido paraibano – PB em base mensal, variando o número de neurônios na camada de entrada, o número de neurônios e a função de transferência na camada intermediária, escolhendo a melhor arquitetura para a base de dados de vazões médias mensais. As melhores arquiteturas testadas apresentaram coeficiente de determinação maior ou igual a 90% durante o teste. Em uma segunda avaliação, considerando também o erro padrão de estimativa, o autor chegou a uma arquitetura com melhor resultado, alcançando coeficiente de determinação de 0,95 e coeficiente de eficiência de 0,94, com erro de estimativa de 4,62. Para aumentar a confiabilidade, Souza (2010) efetuou ainda, os cálculos das médias das inicializações dos parâmetros estatísticos, indicando a melhor arquitetura com 0,92 de coeficiente de melhor desempenho, 0,77 de coeficiente de determinação e 8,29 de erro padrão de estimativa.

Lima (2020) analisou a performance de vários modelos de RNAs com dados de precipitação e deflúvio (chuva-vazão) em uma bacia hidrográfica, localizada no estado do Ceará, sendo o rio do estudo é caracterizado como intermitente. O autor observou que os números e as características dos nós na camada de entrada influenciam significativamente os resultados, o número de nós na camada intermediária que apresentou pouca influência nos resultados, e número de meses usado na fase de treinamento.

Gorodetskaya (2018) discutiu as dificuldades devido à alta variabilidade das escalas temporal e espacial e as não-linearidades das variáveis que descrevem o processo natural da precipitação-vazão em bacias hidrográficas. No estudo de previsão de vazão de curto prazo se propôs a prevê vazões com o horizonte de até 7 dias à frente no rio Paraíba do Sul, o desempenho observado foi melhor para prazos mais curtos de previsões. Nesse caso, a RNA demonstrou resultado satisfatório para as medidas de erros utilizadas, indicando que o modelo foi bem treinado. Todavia, as estimativas para os períodos mais avançados de previsão reforçaram a necessidade do desenvolvimento de métodos preditivos com maior acurácia e robustez na determinação das vazões. Para tal, o autor indicou como uma estratégia, aumentar a capacidade preditiva realizando o ajuste de um modelo para um determinado dia subsequente.

Oliveira, Pedrollo e Castro (2014) avaliaram o desempenho das RNAs para simulação hidrológica da vazão média mensal, utilizando dados meteorológicos e pluviométricos do rio Ijuí. A análise realizada empregou indicadores de desempenho como o coeficiente de NS, RMSE (*Root Mean Square Deviation*), erro relativo absoluto (ER) e análise de sensibilidade. O estudo também comparou o desempenho da RNA com o do modelo SMAP, que é um modelo conceitual concentrado apresentado por Lopes *et al.* (1982). Os resultados apontaram que as simulações utilizando RNA apresentaram estimativas mais consistentes em comparação com SMAP, este último com uma significativa tendência de subestimativa das vazões. O coeficiente NS da simulação com o modelo SMAP foi de 0,672, enquanto que com as RNAs o NS foi de 0,898; o RMSE foi significativamente superior com a aplicação do modelo SMAP, com valor de 55,7 m³/s, enquanto que com as RNAs o valor foi de 38,2 m³/s.

Bravo *et al.* (2008) aplicaram as RNAs para previsões de curto prazo de vazão afluente diária com horizonte de doze dias com intervalo diário, no reservatório de Furnas, comparando os resultados com os do modelo utilizado pelo Operador Nacional do Sistema Elétrico (ONS), buscando prever a vazão afluente de Furnas em Minas Gerais. Para aumentar a representatividade dos resultados, os autores treinaram redes de previsões de chuvas perfeitas empregando as chuvas observadas como previsão de chuva durante a etapa de treinamento e validação da rede e as previsões reais de chuva na etapa de verificação, para utilizar um maior

número de dados durante o treinamento. Os valores das medidas de desempenho obtidos com a rede neural apresentaram-se melhores, em todos os casos, em comparação aos obtidos pelo modelo atualmente utilizado pelo ONS no período analisado.

Na modelagem hidrossedimentológica utilizando RNAs, Campos (2019) estimou a concentração de sedimentos em suspensão (CSS) na bacia do Alto Paraguai com uma abordagem espacial e temporal. A abordagem espacial buscou contornar a escassez de dados da bacia e a temporal e pontual visou estimar a concentração de sólidos suspensos (CSS) na estação fluviométrica de Cuiabá. Na abordagem espacial, o NS do melhor desempenho foi de 0,856 no treinamento e 0,832 na verificação, considerando o nível de significância de 5%, no qual foram desconsideradas as variáveis em que a correlação com sedimentos não foi significativa. Na abordagem temporal (diária), baixa disponibilidade de dados de CSS inviabilizou o uso da técnica da validação cruzada, sendo que as redes então treinadas pela técnica de validação por reamostragem (devido ao pequeno número de amostras) onde menos registros são utilizados, de modo a evitar o superajustamento da rede. Nesse caso, a divisão dos dados foi efetivada em duas partes: treinamento e verificação, diferentemente da validação cruzada tradicional, em que ocorre divisão em três partes: treinamento, validação e verificação. O coeficiente de NS de melhor desempenho foi de 0,777 no treinamento e de 0,776 na verificação.

Teixeira (2020) utilizou RNAs e modelo FIS (*Fuzzy Inference System*) na simulação da concentração de sedimentos em suspensão e da turbidez, empregando dados de precipitação horária de um modelo empírico regional de média móvel exponencialmente ponderada (EWMA) em bacias agrícolas em diferentes escalas. Os modelos RNAs e FIS obtiveram um desempenho muito bom com coeficiente de NS variando de 0,950 a 0,977.

Anmala *et al.* (2000) analisou diferentes arquiteturas de RNAs para prever o escoamento em três bacias hidrográficas no Kansas (EUA) comparando os resultados com modelos empíricos. Os modelos utilizaram a precipitação e as temperaturas mensais foram as variáveis utilizadas nas camadas de entradas, sendo o escoamento médio foi utilizado a variável avaliada na camada de saída. O treinamento foi realizado com diferentes pesos iniciais para ver se um mínimo global foi alcançado, para garantir que o superajustamento não ocorresse. As redes recorrentes foram melhores em prever o escoamento das três bacias.

Jain (2001) realizou o ajuste da curva-chave com 259 dados de cota-descarga em uma abordagem convencional e com a RNA. Foram 198 pares de dados usados para ajustar a curva para treinar a RNA e o modelo convencional, os restantes, 61 utilizado para testes. A arquitetura da RNA com uma camada de entrada (nível) e uma camada de saída (descarga). O número de

neurônios na camada oculta variaram entre 1 e 10, realizando um rigoroso treinamento e testes da rede e a configuração que deu a menor soma dos quadrados mínimos dos erros foi a selecionada. Os erros foram maiores na abordagem convencional no ajuste da curva-chave. À medida que se introduziu mais dados na camada de entrada da RNA, o coeficiente de correlação melhorou e o erros reduziram. A vazão observada e a estimada analisando graficamente, o melhor ajuste foi com a abordagem da rede neural. A soma dos quadrados mínimos dos erros tanto para os dados de treinamento quanto para os dados de teste foi significativamente menor para a RNA em comparação com a abordagem convencional.

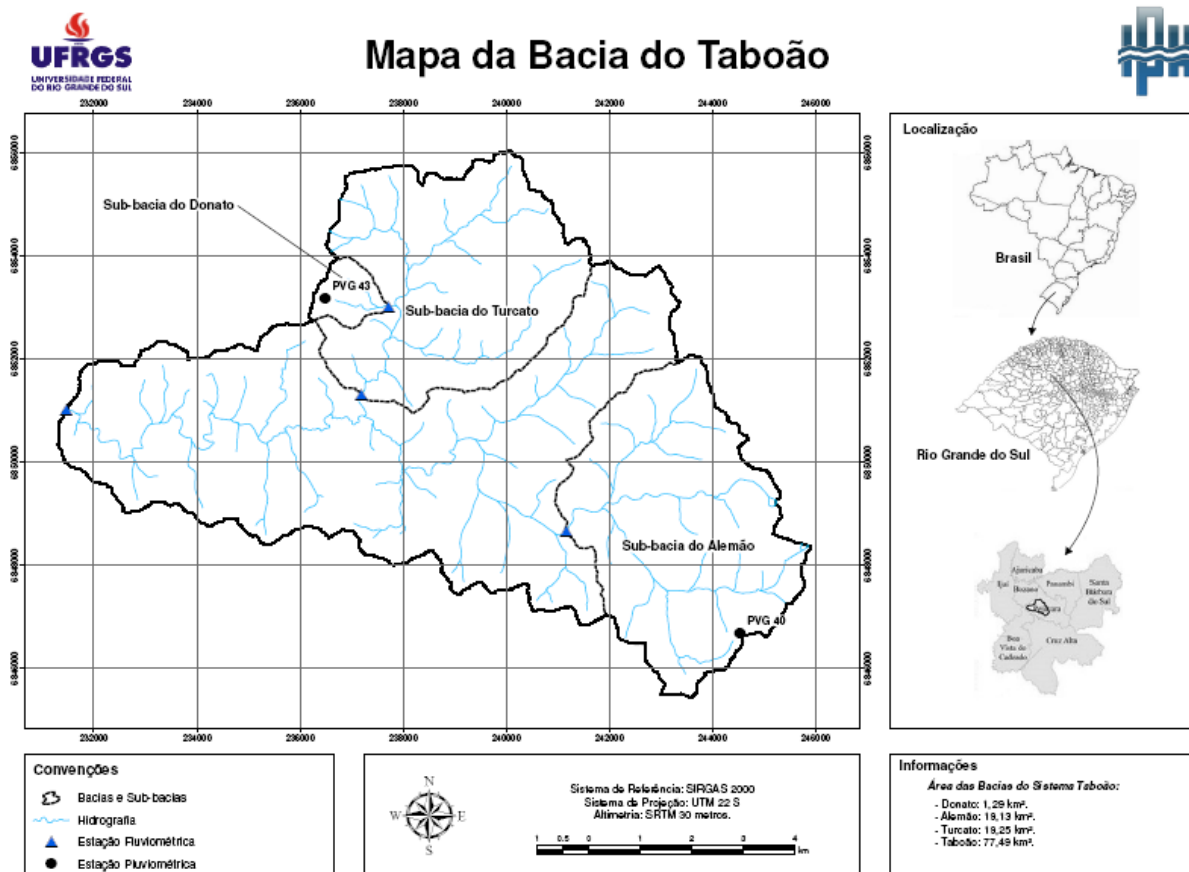
4 MATERIAIS E MÉTODOS

4.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A bacia do arroio Taboão tem uma área de drenagem de 77,5 m² e pertence à bacia Hidrográfica do Rio Ijuí. Conforme FEPAM (2022), a bacia do rio Ijuí situa-se a norte-noroeste do Rio Grande do Sul, entre as coordenadas 27°45' e 26°15' de latitude Sul e 53°15' e 56°45' de longitude Oeste, abrangendo 20 municípios, com uma área de drenagem de 10.649,13 km². Seus principais formadores são os rios: Ijuizinho, Conceição, Potiribu, Caxambu, Faxinal, Fiúza e Palmeira.

As atividades econômicas desta bacia, de maneira geral, estão ligadas ao setor primário, predominando as lavouras de soja e milho no verão e trigo e aveia no inverno. A bacia do arroio Taboão, representada na Figura 4, localiza-se no município de Pejuçara, que dista aproximadamente 377 km de Porto Alegre - RS.

Figura 4- Localização da bacia hidrográfica de Taboão.



Fonte: banco de dados projeto Potiribu IPH/UFRGS, 2016 (desenho Pedro Medeiros)

A escolha da área de estudo se deve, primeiramente, ao fato de estar sendo realizado um monitoramento pelo IPH/UFRGS, desde 1989 em bacias da região, com disponibilidade de um banco de dados hidrológicos superior a 20 anos (CASTRO *et al.*, 1999; CASTRO *et al.*, 2010). Além disso, a região é altamente dependente de atividades agrícolas, sendo, portanto, importante o conhecimento e o monitoramento das variações hidrológicas dos rios da região (OLIVEIRA *et al.*, 2014).

4.1.1 GEOLOGIA, RELEVO E SOLO

Conforme CPRM (2009), na região de estudo a predominância é de basaltos, tratando-se de colinas dissecadas e morros baixos. Os relevos com encostas declivosas estão sujeitos à erosão e à ocorrência de movimentos de massa lentos do tipo rastejo.

O arroio Taboão é um afluente do rio Potiribu, e este último está inserido na região geomorfológica do Planalto Médio do Rio Grande do Sul, que consiste de áreas com solo residual de rochas vulcânicas básicas composto de coxilhas com declividades entre 3 e 15% e matas de galeria próximas as drenagens. Os solos predominantes são os latossolos vermelhos (71,5% da área da bacia), caracterizados por grande profundidade e quantidade de argila. A alta atividade dos argilominerais presentes nesse solo formam estruturas de microagregados, que confere ao solo bom armazenamento de água (característica da argila), e alta taxa de infiltração, sendo conhecidos como falsas areias. A profundidade desse solo pode atingir até mais de uma dezena de metros, caracterizando-se por boa drenagem. Essa característica torna esses solos bons para a agricultura, tanto para culturas de inverno como de verão; desde que corrigida a fertilidade química (CASTRO, 1996).

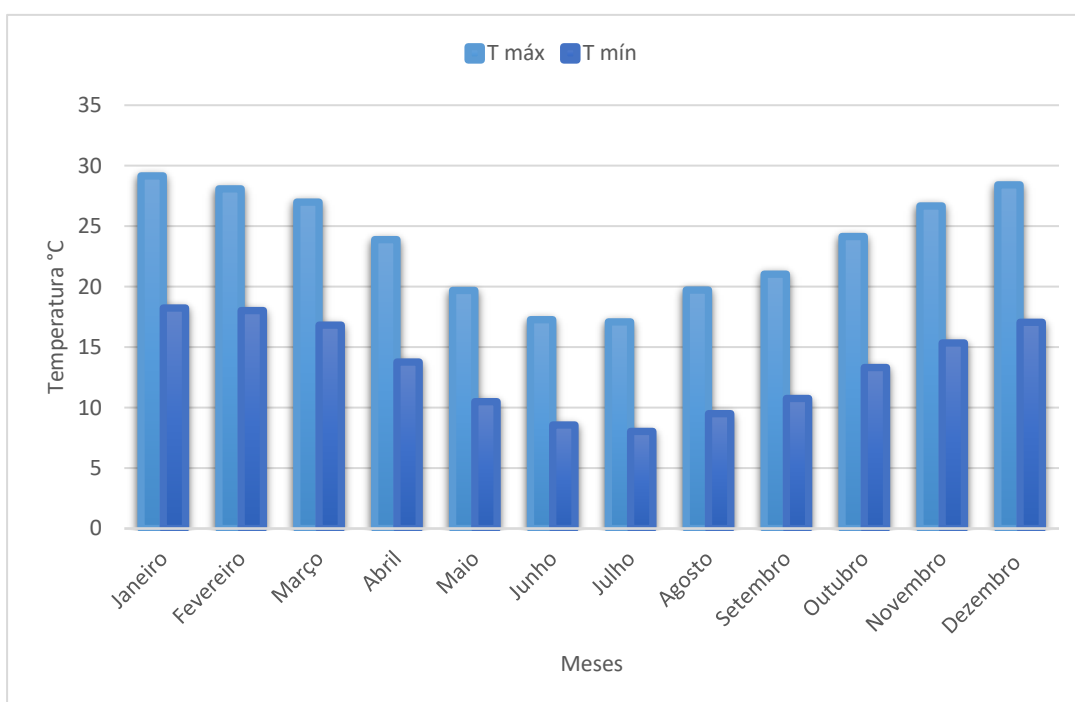
O uso do solo predominante nessa bacia é agrícola com cultivo de soja e milho no verão e aveia e trigo no inverno; e pecuária em algumas propriedades.

De acordo com CPRM (2009), a região apresenta alta vulnerabilidade à contaminação de água subterrânea em função da grande quantidade de discontinuidades nas rochas através das quais ocorre rápida percolação de poluentes. A vulnerabilidade é menor onde os solos são mais espessos e argilosos devido à alta capacidade de retenção de poluentes.

4.1.2 CLIMA E PRECIPITAÇÃO

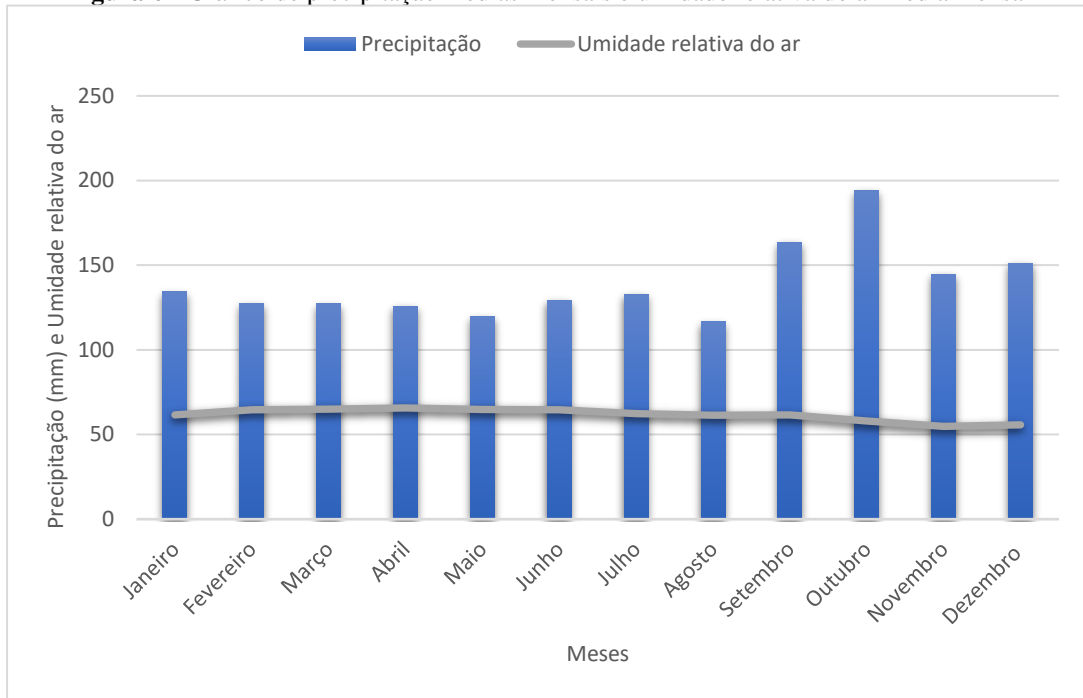
Neimer (1989) define o clima da Região Sul do Brasil como um clima mesotérmico do tipo temperado, caracterizado por sua homogeneidade e por sua unidade regional. As temperaturas mínimas e máximas médias mensais do local registraram, na estação de Cruz Alta, 17°C e 28 °C, respectivamente (Figura 5) no período de 31/01/1961 à 30/04/2022.

Figura 5 - Temperatura máximas e mínimas das médias mensais



Fonte: INMET, 31/01/1961 a 30/04/2022, estação Cruz Alta (83912)

A Figura 6 apresenta as precipitações médias mensais e a umidade relativa na estação meteorológica de Cruz Alta, para o período de 31/01/1961 à 30/04/2022. As precipitações médias mensais são bem distribuídas, com maior precipitação média mensal em outubro (194 mm) e menor precipitação média mensal em agosto (117 mm) e a umidade média mensal relativa entre 54,8% e 65,7%.

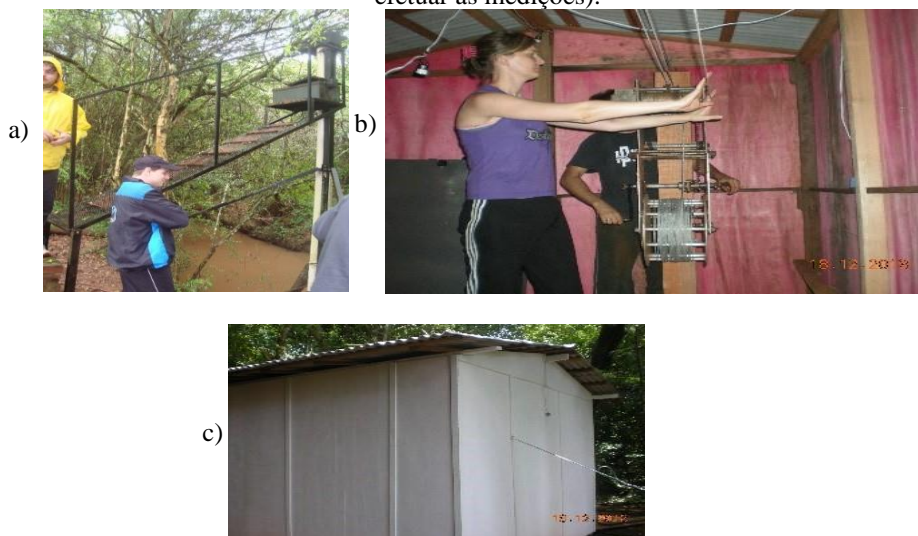
Figura 6 - Gráfico de precipitação médias mensais e umidade relativa do ar média mensal

Fonte: INMET, 31/01/1961 a 30/04/2022, estação Cruz Alta (83912)

4.2 ESTAÇÃO FLUVIOMÉTRICA DO ARROIO TABOÃO

O posto fluviométrico da bacia do arroio Taboão (Figura 7) foi instalado em janeiro de 2002 e está localizado nas coordenadas 28° 26'24''S e 53° 44'30''O. Neste posto foi instalado uma referência de nível (RN) com objetivo de servir como referência para os levantamentos topográficos da seção transversal da seção de medição e para a instalação da régua linimétrica.

Figura 7 - Posto fluviométrico do arroio Taboão (a-instalações da tubulação, linígrafo, caixa com *loggers* e rampa de acesso, b-sistema de cabos teleféricos e roldanas para medições de vazão com cotas altas c-abrigo para efetuar as medições).



Fonte: arquivo pessoal da Prof^a Nilza Castro

Além disso, foi instalado uma tubulação de ferro de 6 metros de comprimento (Fig. 7a) próximo à margem esquerda do arroio Taboão, assim como um abrigo (Fig. 7b e 7c) para a equipe realizar as medições de vazão durante os eventos de chuva. A água do rio entra na tubulação através de uma tubulação secundária (tomada de água), instalada paralela ao leito do rio, conectada à tubulação principal. Na parte superior da tubulação vertical foi fixada uma caixa metálica onde é armazenado o *logger* e a bateria do linígrafo. O *logger* é conectado ao sensor do linígrafo que fica dentro da tubulação, através de cabo elétrico.

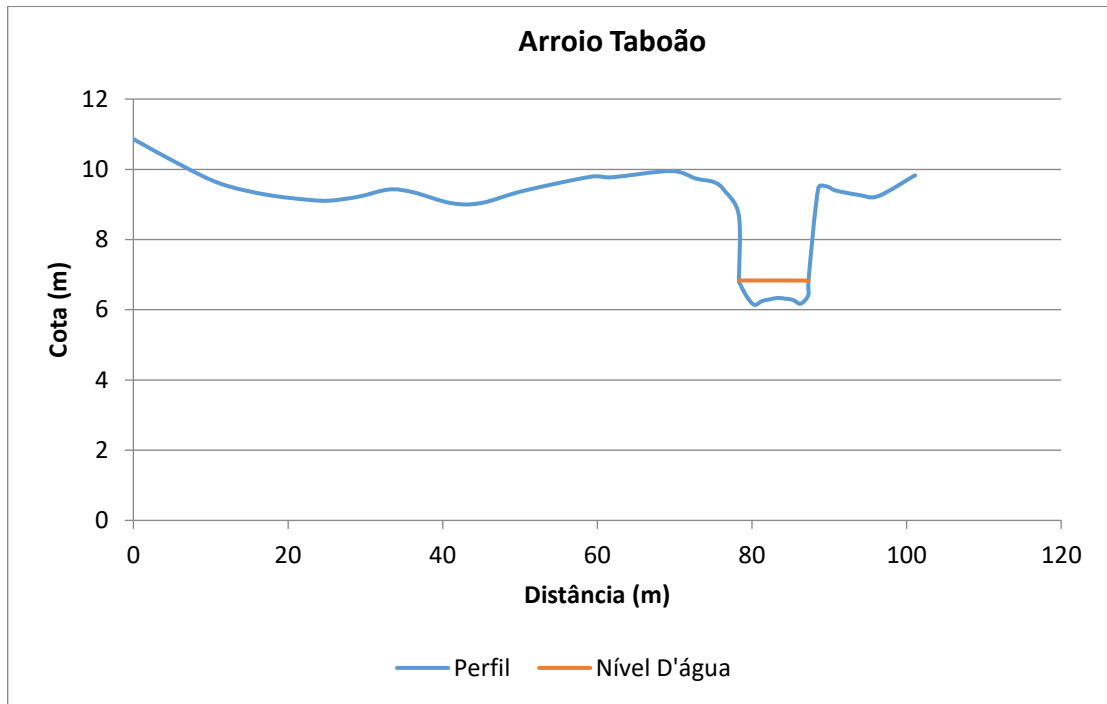
Foi instalada uma rampa para acesso ao *logger* para a coleta dos dados e manutenção do linígrafo. Esse linígrafo desde o início foi do tipo eletrônico. Inicialmente foi instalado um sensor de pressão da marca Druck com *logger* da marca Novus, que funciona com pilhas. Em 2010 esse linígrafo foi substituído por um da marca OTT, modelo Thalimedes com sensor de boia e *logger* da mesma marca OTT e até hoje esse linígrafo encontra-se instalado em perfeitas condições de funcionamento. Também foi instalada uma régua linimétrica nessa estação com objetivo de aferir as leituras do linígrafo.

O levantamento topográfico da seção transversal do arroio Taboão, foi realizado em 2016, incluindo o levantamento batimétrico que é apresentado na Figura 8. Conforme Santos *et al* (2001) a batimetria da seção transversal consiste em um levantamento do relevo da “seção molhada”, ou parte submersa da seção transversal. Define-se como seção transversal de uma

estação fluviométrica o plano essencialmente perpendicular às linhas e corrente correspondente ao local onde são efetuadas as medições diretas de vazão (SANTOS *et al*, 2001).

O perfil transversal tem como referência de nível (RN) o valor de 10 metros. O valor de 10,860 metros corresponde ao início do alinhamento.

Figura 8 - Perfil transversal do arroio Taboão



Fonte: IPH/UFRGS, 2016

Essa seção de medição é bastante estável, e ocorreu somente um desmoronamento da margem esquerda em 12/03/2019 na cota aproximada de 1 metro para cima. Como as medições de vazão após essa data ocorreram todas em cotas inferiores a um metro, essas medições foram consideradas válidas para fazerem parte dos dados para essa pesquisa.

A aquisição dos dados é uma iniciativa do Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul e, nessa estação, e vem sendo realizada desde 2001, sendo que em alguns períodos houve interrupção nas medições e coletas de dados devido à falta de financiamento (2004 a 2006) e à pandemia (a partir de 2020).

As medições de vazão foram realizadas somente com molinete hidrométrico até outubro de 2009, quando foi adquirido um ADCP RiverSurveyor M9 da empresa Sontek RiverSurveyor M9 da empresa Sontek. A partir disto, as medições passaram a ser realizadas com esse equipamento e algumas vezes, quando o nível do rio estava muito baixo, com molinete.

Instalou-se um sistema de cabo teleférico com guincho, cabos de aço, fio eletro condutor e roldanas passando por cima do arroio entre as duas margens, para realizar a medição quando o nível do rio era alto. Quando a cota era baixa o suficiente para uma pessoa entrar dentro do rio de forma segura, a medição era realizada de forma a vau.

Nas medições de vazão com o molinete hidrométrico foi utilizado o método de meia seção para determinação da vazão transportada (SANTOS *et al.*, 2001). Neste método, divide-se a seção transversal em verticais igualmente espaçadas (o número de verticais varia em função da largura entre a margem esquerda e a margem direita) e mede-se a velocidade da água em várias profundidades, em cada vertical (o número de pontos medidos na vertical – de um a seis - varia em função da profundidade das verticais). O cálculo da vazão é realizado multiplicando-se a velocidade média da vertical por sua área de influência. A vazão da seção transversal é a soma das vazões obtidas para cada vertical.

As medições com ADCP foram realizadas conforme orientação do fabricante (SONTEK, 2017). Esse equipamento possui 9 transdutores, sendo 4 feixes duplos de 3,0 MHz/1. MHz posicionados em ângulos de 25° e 1 feixe vertical de 0,5 MHz. Através destes transdutores, o equipamento realiza a medição das profundidades de canais e rios entre 0,3 e 80 m, entretanto, a perfilagem para a medição da velocidade ocorre através de células entre 0,02 e 4 m em uma profundidade de 0,06 até 30 m. Sobre a operação do equipamento, o ADCP realiza as medições de descarga líquida com apoio do software RiverSurveyor Lite. Conforme orientações da Agência Nacional das Águas (ANA), recomenda-se que para a validação de uma medição de vazão se realize no mínimo dois pares de medição (ida e volta) e que o tempo total do conjunto de medições seja superior a 12 minutos.

Foram realizadas 136 medições de vazão entre 01/11/2001 e 12/02/2020 com cotas variando entre 0,254 e 2,745 m e vazão entre 0,536 e 19,37 m³/s. Nesse período, a maior cota registrada no linígrafo foi de 4,26 m – 25/04/16 às 08:15. A cota mínima registrada no linígrafo foi de 0,18 m nos dias 01,03,10,12 e 16/02/2018.

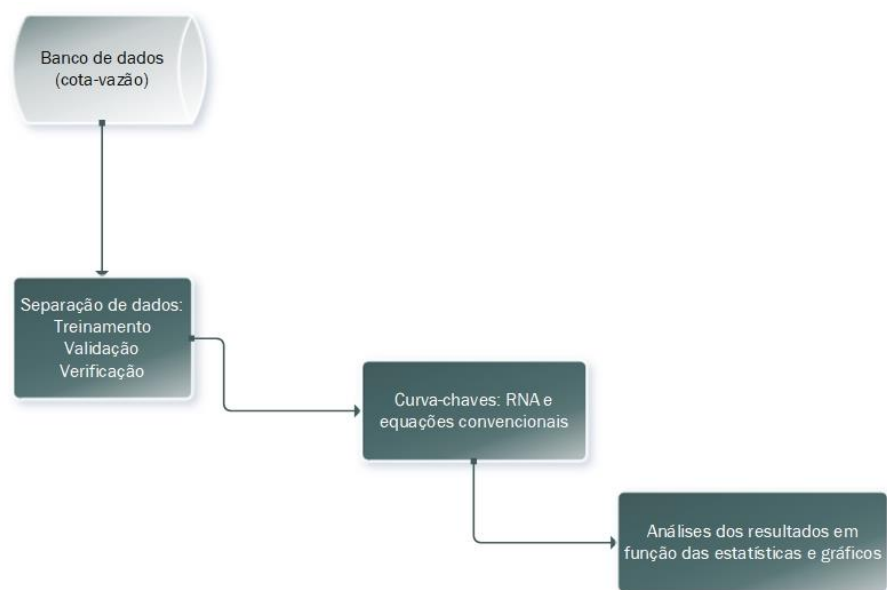
Somente em 0,3% dos registros de cota realizados desde a instalação do linígrafo (2002) até fevereiro de 2020, a cota foi superior à maior cota medida. Além disso, em 0,57% dos registros a cota foi inferior à menor cota medida. Isso sugere que a curva-chave estabelecida nessa pesquisa, utilizando os dados monitorados, possui uma boa confiança, pois em menos de 0,6 % a cota registrada foi superada ou houve registro de valores menores que os medidos.

Os dados de campo utilizados na bacia do arroio Taboão para variável de entrada (cota) e variável de saída (vazão) são dados monitorados e a RNA será treinada para prever se as mesmas fazem as previsões esperadas. As previsões foram avaliadas por meio de indicadores

de desempenho. Aplicações semelhantes são comumente encontradas no campo dos recursos hídricos para a aplicação de modelos que utilizam redes neurais, principalmente na previsão de variáveis hidrológicas como níveis, vazão, precipitação e umidade (MATOS, 2012). Neste ponto, a rede elaborada extrai características importantes de padrões de informações apresentados com a finalidade de criar uma representação específica para o problema. Essa etapa de treinamento é um processo iterativo onde pesos e *bias* (vieses) são ajustados, buscando-se a minimização do erro na saída da RNA (MINUCCI, 2014).

Serão elaboradas curvas-chaves convencionais utilizando três equações: linear, potencial e polinomial, para avaliar se a curva-chave estimada com redes neurais artificiais tem melhor desempenho que essas curvas-chaves tradicionais, através de comparações com indicadores de desempenho e análise gráfica do comportamento da RNA e das três equações, todas simuladas através do programa *Octave*, conforme o fluxograma a seguir:

Figura 9 – Fluxograma da comparação da curva-chave com RNA e equações convencionais



Fonte: autora

4.3 DETERMINAÇÃO DA CURVA-CHAVE POR AJUSTES TRADICIONAIS

As equações simuladas para estimativa da curva-chave: linear, potencial e polinomial com as equações correspondentes citadas no Tópico 2.1, foram através do programa Octave. As medições utilizadas pelas equações, totalizaram 102 medições de cotas-vazão para a calibração pelo método de ajuste dos mínimos quadrados. Para a estimativa da curva-chave, assim como a etapa de verificação da RNA, 34 medições não foram utilizadas na calibração e, verificou-se os índices de desempenho da mesma.

4.4 DETERMINAÇÃO DA CURVA-CHAVE POR AJUSTES RNA

A arquitetura da rede neural utilizada nessa pesquisa é do tipo propagação progressiva de múltiplas camadas MLP (Multilayer Perceptron, ou Multilayer Feed Forward Network) com uma camada de entrada, uma camada oculta e uma camada de saída. Nessa rede os neurônios de cada camada recebem os sinais dos neurônios da camada anterior e propagam a saída dos neurônios para a camada posterior. A função de ativação utilizada nos neurônios artificiais é a função sigmoide unipolar também conhecida como função logística.

A simulação da RNA foi realizada utilizando recursos desenvolvidos com o programa *Octave*. Para avaliar o desempenho da rede neural, calculou-se os erros " e_s " e " e_w " a partir dos resultados de camadas anteriores. Assim, monitorou-se a precisão do modelo, ajustando os pesos w_k e vieses para que a rede gradualmente converjisse para determinados valores. Os vetores de entrada produzam as saídas esperadas, encontrando a melhor RNA. Porém, se a rede for treinada excessivamente, poderá ocorrer o superajustamento. Para que isso não aconteça, a validação cruzada é empregada, e as amostras são divididas em treinamento, validação e verificação. A validação é a amostra utilizada para a verificação dos erros da rede durante o treinamento. A verificação é utilizada após o treinamento, para verificar o desempenho da rede em uma amostra que não participou do treinamento, para garantir a capacidade de generalização do modelo. Além disso, é necessário limitar o número de neurônios na camada interna pela análise da complexidade, segundo o paradigma descrito anteriormente.

Sendo assim, a aplicação da RNA baseou-se na técnica da validação cruzada, com três etapas: treinamento, validação e verificação. Das 136 medições (cotas-vazão) disponibilizadas, sendo que 68 foram selecionadas para o treinamento (com máximos e mínimos incluídos nesta amostra de treinamento), 34 para a validação e 34 para a verificação.

Essa separação das medições é sistemática, em sequências ordenadas em ordem crescentes de pares ordenados, sem aleatoriedades. As medições de extremos superior e inferior são incluídos excepcionalmente no treinamento. Sari (2017) dividiu os dados de sua pesquisa por meio de amostragem sistemática, que possibilitou a seleção da amostra e a identificação das amostras residuais da seleção, sem falhas. Campos (2019) também fez a divisão dos registros para o treinamento e a verificação pela técnica de amostragem sistemática, resultando praticamente as mesmas distribuições de frequência para as amostragens de treinamento, validação e verificação.

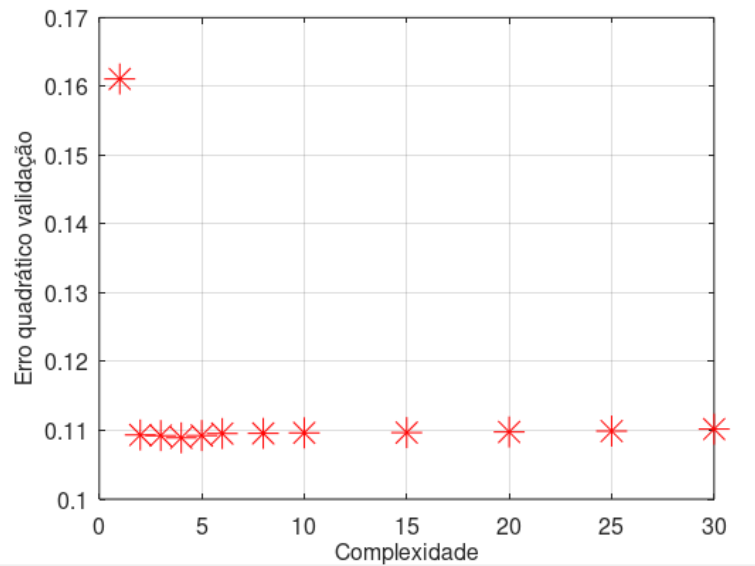
Para avaliar a quantidade de neurônios na camada interna, o procedimento é realizado com uso de repetições e análise gráfica variando-se o número de neurônios, até encontrar a menor complexidade que ainda apresenta desempenho semelhante a redes mais complexas.

Na etapa de verificação buscou-se analisar se a RNA escolhida resultou em uma boa estimativa para curva-chave, a partir do emprego dos dados disponíveis do arroio Taboão. A rede neural foi treinada com 50% das amostras, sendo as restantes repartidas igualmente para as amostragens de validação e de verificação.

5 RESULTADOS E DISCUSSÕES

Na Figura 10 é apresentado o gráfico com a estatística de desempenho (erro quadrático na validação) para a análise de complexidade de rede realizada. Foram testados 30 neurônios até 1 neurônio para a camada interna, com 10 repetições e 50.000 ciclos.


Figura 10 - Gráfico da simulação da quantidade de neurônios na camada interna da RNA



Verifica-se que, com dois neurônios na camada interna, já se tem uma boa aproximação para a análise da menor complexidade de rede. Já para um neurônio apenas, o erro quadrático aumentou de forma significativa e, aumentando para mais neurônios, os valores ficaram praticamente constantes. Dessa forma, utilizar dois neurônios resulta uma aproximação equivalente à obtida com redes mais complexas, conforme o paradigma da complexidade.

A rede neural selecionada após as análises de complexidade é apresentada na Figura 11.

Figura 1 - Configuração da rede neural resultante: na camada de entrada a variável cota, dois neurônios na camada interna e camada de saída a variável descarga (vazão).



5.1 AJUSTES DO MODELO: RNA

Os valores das estatísticas nas etapas de treinamento, validação e verificação foram muito bons, inclusive o coeficiente de eficiência NS (0,99) (Tabela 1). O erro médio absoluto foi menor no treinamento 0,289 m³/s e maior na verificação 0,322 m³/s. O quantil %E05 em torno de -0,8 m³/s para todas as etapas, % E95 menor valor na validação com 0,430 m³/s e maior valor na verificação com 0,730 m³/s.

Tabela 1 – Estatísticas de desempenho da RNA

	EAM	EM	% E05	% E50	% E95	NS
	m ³ /s	m ³ /s	m ³ /s	m ³ /s	m ³ /s	-
TREINAMENTO	0,289	0,005	-0,816	0,053	0,524	0,992
VALIDAÇÃO	0,292	-0,024	-0,784	0,020	0,430	0,986
VERIFICAÇÃO	0,325	-0,043	-0,772	-0,012	0,756	0,986

5.2 AJUSTES DOS MODELOS: LINEAR, POTENCIAL E POLINOMIAL

A curva-chave foi ajustada com a mesma proporção de medições que foi utilizada para treinar e validar a rede (calibração). Isto é, a etapa de treinamento e validação, totalizando 102

dados. Utilizando as três equações tradicionais: linear, potencial e polinomial. A calibração das três equações resultou em menor erro médio absoluto na equação polinomial 0,322 m³/s. Os erros extremos negativos (%E05) e positivos (%E95) variaram de -0,699 m³/s a -0,851 m³/s e 0,660 m³/s a 1,023 m³/s m no modelo potencial e linear, respectivamente (Tabela 2). O coeficiente de NS, na etapa de calibração, em torno de 0,99 para as três equações.

Tabela 2 - Estatísticas de desempenho das equações convencionais

	EAM	EM	% E05	% E50	% E95	NS
	m ³ /s	m ³ /s	m ³ /s	m ³ /s	m ³ /s	-
LINEAR	0,334	0,000	-0,851	0,020	0,660	0,986
POTENCIAL	0,356	0,077	-0,699	0,037	1,023	0,985
POLINOMIAL	0,322	0,000	-0,807	-0,003	0,685	0,987

5.3 COMPARAÇÃO DOS MODELOS AJUSTADOS

Para comparar as estimativas da RNA com as estimativas das curvas-chave das três equações, as medições analisadas foram da etapa da verificação, na qual não participou de nenhum ajuste realizado anteriormente.

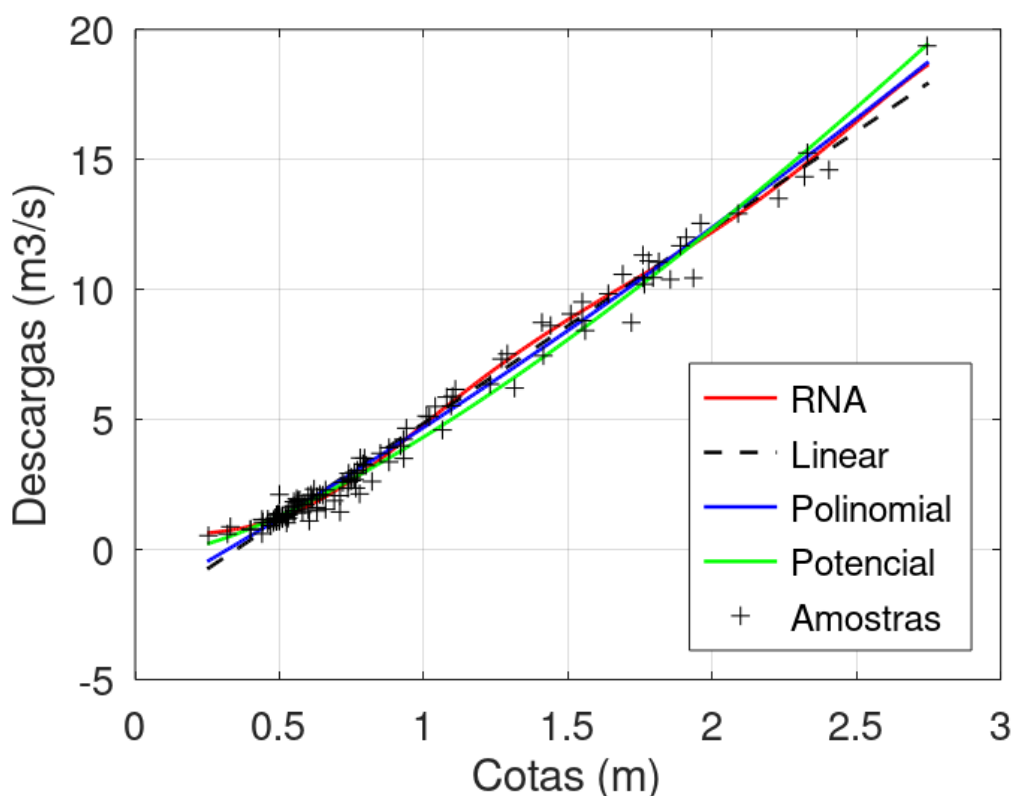
Tabela 3 - Comparação dos indicadores de desempenho das curvas-chave convencionais e RNA

	EAM	EM	% E05	% E50	% E95	NS
	m ³ /s	m ³ /s	m ³ /s	m ³ /s	m ³ /s	-
LINEAR	0,355	-0,057	-0,997	-0,016	0,722	0,984
POTENCIAL	0,343	0,031	-0,902	-0,050	0,943	0,984
POLINOMIAL	0,329	-0,052	-0,923	-0,026	0,813	0,985
RNA	0,322	-0,036	-0,771	0,002	0,730	0,985

Na análise comparativa das equações tradicionais com o modelo de RNA, comparando o conjunto das estatísticas (Tabela 3), o desempenho da RNA foi melhor, pois a maioria das estatísticas de desempenho foi mais favoráveis do que as do modelo convencional. Os valores de NS foram similares para todos os modelos. A equação linear resultou no maior erro médio absoluto (0,355 m³/s) e maior erro extremo negativo %E05 (-0,997 m³/s). A equação potencial resultou no maior erro extremo positivo %E95 (0,943 m³/s). Assim, através dessas análises, a equação polinomial e a RNA obtiveram menores erros dentre as testadas, sendo a RNA com menores erros na comparação geral (dos cinco erros analisados, a RNA tem três menores, sendo menor EAM: 0,322 m³/s; menor %E05: -0,771 m³/s; menor %E50: 0,002 m³/s)

Para averiguar o comportamento das três equações e da RNA, foram geradas cotas a cada 1 cm utilizando as curvas, e os valores gerados com as curvas foram plotados com as medições realizadas. O resultado da comparação gráfica é apresentado na Figura 12.

Figura 12 - Gráfico das equações convencionais e RNA



A equação polinomial (azul) que obteve os menores erros estatísticos de desempenho em comparação com a equação potencial (verde) e a linear (tracejada), tem um comportamento

mais parecido com a RNA (vermelho). Porém para cotas abaixo de 32 cm resultou em vazões negativas, fazendo com que essa equação não seja aplicável para esse intervalo. A equação linear também resultou em valores negativos para cotas menores de 34 cm.

Um ponto positivo nessa pesquisa é que as medições realizadas abrangeram um intervalo bem amplo de cotas (0,25 a 2,75 m), e, como comentado no Tópico 4.2, em menos de 0,6 % a cota registrada no linígrafo foi superior a maior cota medida e inferior à menor cota medida.

A curva-chave da RNA resultou em uma maior precisão para cotas mais baixas. Para as cotas altas, a polinomial ficou bem parecida com a RNA, com mesmo percurso no extremo superior, observado no gráfico.

A equação potencial foi a única das equações convencionais que não resultou em valores negativos para cotas baixas e, observando o gráfico, a potencial descreveu um comportamento que distanciou mais das outras curvas-chaves plotadas. No extremo negativo a potencial descreveu bons resultados, como na RNA, mas ao decorrer do percurso de distanciou das outras curvas-chaves e da RNA.

As amostras plotadas no gráfico mostraram que a rede neural descreveu melhor o comportamento, sendo que apenas no ponto mais extremo superior não foi possível estimar com maior precisão. Neste caso, precisaria de medições de cotas mais altas para maior confiabilidade. Como as amostras oscilam muito durante o percurso, o ponto que ficou mais distante pode ter sido por aleatoriedade dos dados.

Portanto, apesar do coeficiente NS ter sido praticamente igual para todas as quatro curvas-chaves, como a RNA teve os menores erros e descreveu melhor o percurso das amostras, podemos concluir que a RNA teve um ótimo desempenho, melhor que as equações clássicas geralmente utilizadas para curva-chave e faz uma boa aproximação para a curva-chave da área de estudo.

6 CONSIDERAÇÕES FINAIS

O presente estudo se propôs a avaliar as redes neurais como uma forma alternativa às estimativas com curvas-chave. As estimativas foram comparadas com técnicas tradicionais de curva-chave, tais como linear, potencial e polinomial. Os desempenhos de todos os métodos testados foram considerados satisfatórios, em termos de NS. Mesmo os valores do NS tendo sido praticamente iguais, ao visualizar as curvas-chave das equações linear, polinomial, potencial e da RNA, elas distanciam principalmente nos extremos mínimos e máximos. A RNA se adapta nesses casos, e tem, no geral, menores erros que as outras equações testadas, sendo, portanto, a melhor escolha dentre as testadas.

A desvantagem das RNAs é que a sua utilização é restrita ao intervalo dentro dos limites do domínio utilizado no treinamento, não sendo possível, portanto, extrapolar a curva-chave para cotas menores ou maiores dos limites para os quais as redes foram treinadas. Esta restrição também se aplica às fórmulas tradicionais, sendo que duas das três fórmulas testadas (linear e polinomial) resultaram em vazões negativas para cotas baixas. Porém, em muitos casos, uma pequena extrapolação para fora do domínio de ajuste pode ser admitida, embora com muito cuidado, mediante análise física e da tendência observada graficamente. Além disso, a elaboração de um modelo com RNAs tem maior complexidade que o ajuste de uma curva convencional, bem como a sua aplicação, que sempre requer recursos computacionais.

Essa pesquisa demonstrou que é possível realizar um excelente ajuste de curva-chave com RNA, sendo melhor que o ajuste das curvas tradicionalmente utilizadas, em uma estação fluviométrica bastante estável e aproximadamente linear.

Embora as curvas-chave tradicionais possam, em muitos casos, apresentar desempenho suficiente, e também maior facilidade de uso, o emprego de uma rede neural, quando esta é disponível (os recursos computacionais necessários estão se tornando progressivamente triviais) apresenta vantagens, mesmo que pequenas. Por isso, pode ser desejável o uso de RNAs para este fim, especialmente se é necessário gerar uma série grande de vazões, cuja precisão seja importante.

A RNA contornou o problema de vazões negativas obtidas pelas equações linear e polinomial, garantindo resultados mais confiáveis. Não sendo uma seção sujeita a remanso, uma curva-chave que resulte em vazões negativas não é aceitável. A RNA resultou, portanto, valores mais precisos e é uma vantagem de contornar essas incertezas nos extremos. Assim, a RNA que descreveu melhor o comportamento de uma curva-chave e obteve menores erros de desempenho é uma boa proposta para estimar uma curva-chave.

A única maneira de melhorar a precisão das curvas-chaves seria realizar medições nos pontos mais baixos e mais altos que o arroio atinge. Porém, para cotas muito baixas a precisão da medição cai um pouco, pois não é possível realizar vários pontos de medição com o molinete com cota muito baixa, e o ADCP tem um limite de lâmina d'água mínima para seu funcionamento adequado. Para o extremo superior, é muito raro a equipe estar em campo no exato momento da ocorrência de um evento extremo, e a medição pode ser muito perigosa.

Recomenda-se aplicar essa mesma metodologia, em outras estações fluviométricas mais complexas, não tão estáveis e próximas da linearidade, para avaliar o potencial de modelos com RNAs serem mais eficientes que as equações clássicas, em situações de maior instabilidade e maior complexidade. À medida que mais dados de entrada são disponibilizados e ou o acréscimo de mais variáveis de entrada na camada da rede, a confiabilidade do modelo aumentará. A inclusão de mais variáveis de entrada, como chuvas, níveis em tempos antecedentes ampliaria a complexidade da modelagem e aumentaria a precisão das estimativas.

Devido à capacidade das redes neurais aproximar bem modelos não-lineares, a complexidade da modelagem não seria um grande problema, devido aos avanços das tecnologias e dos recursos disponíveis, como o programa *Octave* que é disponibilizado gratuitamente aos usuários. Além disso, o cálculo de vazões a partir de cotas torna-se facilitado, pois depende de recursos de aplicação imediata para a execução da rede neural, dependentes de um *software* livre como é o caso do *Octave*. Porém, uma alternativa para uso manual, ou com uma planilha eletrônica, pode ser desejável. Assim, no Tópico 8, uma tabela é gerada pela RNA com intervalos de 1 cm de cota.

7 REFERÊNCIAS

ANA – Agência Nacional de Águas e Saneamento Básico. Disponível em <<https://www.gov.br/ana/pt-br>> Acesso em 24 de abr 2022.

ANMALA, J.; ZHANG, B. and GOVINDARAJU, R.S. Comparison of ANNs and empirical approaches for predicting watershed runoff. *Jornal of water resources planning and management*, 2000.

ASCE (Task Committee on Application of Artificial Neural Networks in Hydrology). *Artificial neural networks in hydrology I: Preliminary Concepts*, 2000.

BASSO, Luís Alberto; MOREIRA, Luiza Gehrke Ryff; PIZZATO, Fernanda. A influência da precipitação na concentração e carga de sólidos em cursos d'água urbanos: o caso do arroio Dilúvio, Porto Alegre, RS. *Geosul*, v. 26, n. 52, p. 145-163, 2011. DOI: <https://doi.org/10.5007/2177-5230.2011v26n52p145>

BRASIL. Constituição da República Federativa do Brasil de 1988. Brasília, DF: Presidente da República, [2016]. Disponível em: http://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm. Acesso em 28 abr. 2022.

BRAVO, J.M el tal. Previsão de Curto Prazo de Vazão Afluente ao Reservatório de Furnas Utilizando Redes Neurais Artificiais. *Revista Brasileira de Recursos Hídricos* Volume 13 n.2., 2008.

CAMPOS, J.A. Modelagem Hidrossedimentológica em escala espacial e temporal na bacia do Alto Paraguai utilizando redes neurais artificiais. *Dissertação de Mestrado*. Porto Alegre, 2019.

CASTRO, N.M. dos R. *Ruissellement et érosion sur des bassins versants de grande culture du plateau basaltique du sud du Brésil* (Rio Grande do Sul). 224p. Tese (doutorado em Geografia Física Hidrologia e Geomorfologia). *Université Louis Pasteur, Strasbourg*, 1996.

CASTRO, N.M. dos R.; AUZET, A.-V.; CHEVALLIER, P.; LEPRUN, J.C. Land use change effects on runoff and erosion from plot to catchment scale on the basaltic plateau of Southern Brazil. *Hydrological Processes*, 1999.

COLLISCHONN, W.; DORNELLES, F. *Hidrologia para Engenharia e Ciências Ambientais*. Porto Alegre, 2013.

CPRM – Serviço Geológico do Brasil. *Geodiversidade do Estado do Rio Grande do Sul*. CPRM, 2010.

CPRM – Serviço Geológico do Brasil. *Mapa geodiversidade do estado do Rio Grande do Sul*. CPRM, 2009.

DAWSON, C.W; WILBY, R.L. Hydrological modelling using artificial neural networks. *Progress in Physical Geography* 25,1 pp. 80–108. 2001

Deep Learning Book Brasil. Disponível em; <<https://www.deeplearningbook.com.br/o-neuronio-biologico-e-matematico/>> Acesso em 22 de mar 2022.

DEPINÉ, H.; CASTRO, N.M.R; PINHEIRO, A.; PEDROLLO, O. Preenchimento de Falhas de Dados Horários de Precipitação Utilizando Redes Neurais Artificiais. *Revista Brasileira de Recursos Hídricos* Volume 19 n.1. 2014

EATON, John W.; BATEMAN, David; HAUBERG, Ren; WEHBRING, Rik (2022). GNU Octave version 7.1.0 manual: a high-level interactive language for numerical computations. URL <https://www.gnu.org/software/octave/doc/v7.1.0/>

ENGIE. Tudo o que você precisa saber sobre a crise hídrica. Disponível em <https://www.alemnaenergia.engie.com.br/tudo-o-que-voce-precisa-saber-sobre-a-crise-hidrica/?gclid=Cj0KCQjwxtSSBhDYARIsAEn0thS2Ft0JL1xQLKx9EjaSDJCZ4etRQ5-_KlbUEaXKr6bM5YZemT0AJQcaAhW3EALw_wcB> Acesso em 12 abril 2022.

FAVORETO, R.S *et al.* A técnica da rede neural artificial aplicada na previsão de vazões. Curitiba – Paraná, 2001.

FEPAM - Fundação Estadual de Proteção Ambiental Henrique Luis Roessler. Disponível em <http://www.fepam.rs.gov.br/qualidade/bacia_uru_ijui.asp> Acesso em 22 de mar 2022.

FILHO, J.A.P. Modelo híbrido EMD-RNA de previsão de cotas fluviiais médias diárias em Manaus a partir de informações climáticas de larga escala. Tese de doutorado. Rio de Janeiro, 2019.

FONTANA, E. Introdução aos Algoritmos de Aprendizagem Supervisionada. 2020.

FUNKE, A.J. Análise erosivo – deposicional de leito do Rio Potiribu a montante da barragem andorinhas, Bozano e Ijuí – RS. Trabalho de Conclusão de Curso. Porto Alegre, 2018.

GÉRON, A. Hands-on Machine Learning with Scikit-Learn, Keras & TensorFlow.
HAYKIN, S. Redes Neurais: princípios e práticas. Tradução de Paulo Martins Engel (2 ed.). Porto Alegre: Bookman, 2001.

GORODETSKAYA, Y.; FONSECA, L.G; RIBEIRO, C.B.M. Previsão de vazão a curto prazo utilizando redes neurais artificiais. Estudo de caso: Rio Paraíba do Sul. III Simpósio de Recursos Hídricos da Bacia o Rio Paraíba do Sul. Juiz de Fora- MG, 2018.

GRISON, F.; KOBIYAMA, M. Erros e incertezas na estimativa de vazões e no traçado de curvas-chaves. XVIII Simpósio Brasileiro de Recursos Hídricos. Campo Grande -MS. 2009.

HECHT-NIELSEN, R. Kolmogorov's mapping neural network existence theorem. International Conference on Neural Networks. San Diego, 1987.

HECHT-NIELSEN, R. 1990. Neurocomputing. Addison-Wesley, 1990.

HORNIK, K. Approximation capabilities of multilayer feedforward networks. Neural networks, United States, 1991.

INMET – Instituto Nacional de Meteorologia. Banco de dados meteorológicos para ensino e pesquisa. Série de dados históricos de Cruz Alta – RS (estação nº). Disponível em <inmet.gov.br/portal/index.php?r=bdmep/bdmep>. Acesso em abril 2022.

JACCON, G.; CUDO, K.J. Hidrologia. Curva-Chave. Análise e Traçado. Brasília, 1989.

KARUNANITHI, N; GRENNEY. Neural Networks for river flow prediction. J. Comput. Civ. Eng, 1994. Pags 201-220.

LANNA, A. E.; INDURSKY, A. B. Predição de vazões médias mensais com modelos empíricos. Revista Brasileira de Engenharia, Caderno de Recursos Hídricos, ABRH, Brasil, v. 1, p. 59-91, 1983.

LIMA, C.H.R.; FILHO, W.M.F. Análise de modelos de redes neurais aplicados ao processo chuva-deflúvio no semiárido. XV Simpósio Brasileiro de Recursos Hídricos. 2020.

LUCCHESI, L.V.; OLIVEIRA, G.G.; PEDROLLO, O.C. Attribute selection using correlations and principal components for artificial neural networks employment for landslide susceptibility assessment. Environmental Monitoring and Assessment. 2020. DOI: <https://doi.org/10.1007/s10661-019-7968-0>

MATOS, A.B. Efeito do controle de montante na previsão hidrológica de curto prazo com redes neurais: aplicação à bacia do Ijuí. Dissertação de Mestrado. Porto Alegre, 2012.

MATSUNAGA, V.Y. Curso de Redes Neurais utilizando o MATLAB.

McCulloch WS, Pitts W (1943) A logical calculus of the ideas immanent in nervous activity. Bull Math Biophys. <https://doi.org/10.1007/BF02478259>

MINUCCI, L. R. Regionalização de série de vazões utilizando redes neurais artificiais. Dissertação de Mestrado. Curitiba- Paraná, 2014.

NIMER, F. Climatologia da Região Sul in Climatologia do Brasil. Rio de Janeiro, 1989.

OLIVEIRA, N.T. de; CASTRO, N.M. dos R.; GOLDENFUM, J.A. Influência da Palha no Balanço Hídrico em Lisímetros. Revista Brasileira de Recursos Hídricos, v. 15, n. 2, p. 93-103, 2010.

OLIVEIRA, G.G.; PEDROLLO, O.C.; CASTRO, N.M.R. O desempenho das redes neurais artificiais (RNAs) para simulação Hidrológica Mensal. Revista Brasileira de Recursos Hídricos. Volume 19 n.2. 2014.

PAZ, A.R. Hidrologia Aplicada. Caxias do Sul – RS, 2004.

PEDROLLO, O.C. Previsão de curto prazo de níveis com redes neurais artificiais para a cidade de Estrela (RS): resultados preliminares. Associação Brasileira de Recursos Hídricos. Florianópolis, 2017.

PEDROLLO, O.; PEDROLLO, M. Sistema de alerta de cheias da bacia do rio Caí. 2013.

RAUBER, T.W. Redes Neurais Artificiais. Espírito Santo, 1998.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. Psychological review, United States, 1958.

RUMELHART, D.E; HINTON, G.E; WILLIAMS, R.J. Learning representations by back-propagating errors. 1986.

SANTOS, C.C. Modelagem de bacias urbanas com redes neurais artificiais. Dissertação de mestrado. São Paulo, 2001.

SANTOS, I; FILL, H.D; SUGAI, M.R.v.B; BUBA, H; KISHI, R.T; MARONE, E; LAUTERT, L.F. Hidrometria Aplicada. Curitiba, PR. 2001

SARI, V. Monitoramento e modelagem da produção de sedimentos em uma bacia hidrográfica no noroeste do Rio Grande do Sul. Tese de doutorado. Porto Alegre, RS. 2017.

SCHEREN. R.S; ROBAINA, L.E.S. Classificação geomorfométrica da bacia hidrográfica do rio Ijuí – RS. Santa Maria, 2019.

SEFIONE, A.L. Estudo comparativo de métodos de extrapolação superior de curvas-chave. Dissertação de Mestrado. Porto Alegre, 2002.

SHEREN, R.S. ROBAINA, L.E.S. Classificação geomorfométrica da bacia hidrográfica do rio Ijuí, RS. 2019

SILVA, I.V; SPATTI, D.H e FLAUZINO, R.A. Redes Neurais Artificiais para Engenharia e Ciências Aplicadas. São Paulo, 2016.

SOUSA, W.S.; SOUSA, F.A.S. Rede neural artificial aplicada à previsão de vazão da Bacia Hidrográfica do Rio Pincó. Revista Brasileira de Engenharia Agrícola e Ambiental v.14, n.2, p.173–180. Campina Grande – Paraíba, 2010.

TUCCI, C.E. Capítulo 14 do Livro Água Doce. Dezembro, 1997. Porto Alegre, RS

WIDROW, B.; HOFF, M.E. Adaptive switching circuits. IRE WESCON Convention Record, Part 4. New York, 1960.

8 ANEXO

Tabela 4: Curva-chave gerada pela RNA (cota em metros e vazão em m³/s)

NaN	0	0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08	0,09
0,2	0,586	0,595	0,603	0,613	0,623	0,633	0,645	0,657	0,67	0,683
0,3	0,698	0,713	0,729	0,747	0,765	0,784	0,804	0,825	0,848	0,871
0,4	0,896	0,922	0,949	0,978	1,008	1,039	1,071	1,105	1,141	1,178
0,5	1,216	1,256	1,297	1,34	1,384	1,43	1,478	1,527	1,578	1,63
0,6	1,684	1,739	1,796	1,854	1,914	1,976	2,039	2,103	2,169	2,237
0,7	2,305	2,375	2,447	2,519	2,593	2,668	2,745	2,822	2,901	2,98
0,8	3,061	3,142	3,224	3,308	3,392	3,476	3,562	3,648	3,734	3,822
0,9	3,909	3,997	4,086	4,175	4,264	4,353	4,443	4,532	4,622	4,712
1	4,802	4,892	4,982	5,071	5,161	5,25	5,34	5,429	5,517	5,606
1,1	5,694	5,782	5,87	5,957	6,043	6,13	6,216	6,301	6,386	6,47
1,2	6,554	6,638	6,721	6,803	6,885	6,967	7,048	7,128	7,208	7,287
1,3	7,366	7,444	7,522	7,599	7,676	7,752	7,828	7,903	7,977	8,052
1,4	8,125	8,199	8,271	8,344	8,415	8,487	8,558	8,628	8,699	8,769
1,5	8,838	8,907	8,976	9,044	9,113	9,18	9,248	9,315	9,383	9,45
1,6	9,516	9,583	9,649	9,715	9,781	9,847	9,913	9,979	10,044	10,11
1,7	10,176	10,241	10,307	10,372	10,438	10,503	10,569	10,635	10,701	10,767
1,8	10,833	10,899	10,966	11,033	11,1	11,167	11,234	11,302	11,37	11,438
1,9	11,506	11,575	11,644	11,714	11,783	11,854	11,924	11,995	12,067	12,138
2	12,211	12,284	12,357	12,43	12,505	12,579	12,654	12,73	12,806	12,883
2,1	12,96	13,038	13,116	13,195	13,275	13,355	13,435	13,517	13,598	13,681
2,2	13,763	13,847	13,931	14,015	14,1	14,186	14,272	14,359	14,446	14,533
2,3	14,621	14,71	14,799	14,889	14,979	15,069	15,16	15,251	15,342	15,434
2,4	15,526	15,618	15,711	15,804	15,897	15,99	16,083	16,176	16,27	16,363
2,5	16,457	16,55	16,643	16,736	16,829	16,922	17,014	17,106	17,198	17,289
2,6	17,38	17,47	17,56	17,65	17,738	17,826	17,914	18	18,086	18,171
2,7	18,255	18,338	18,421	18,502	18,582	18,661	18,739	18,816	18,892	18,966

Exemplo de leitura da vazão - cota 1,65 (1ª coluna descer até a linha correspondente à 1,60). Avançar na mesma linha até a coluna 0,05 ($1,60\text{m} + 0,05\text{m} = 1,65\text{ m}$). Fazer a leitura da vazão nessa célula → 9,847 m³/s