

UNIVERSIDADE FEDERAL DO PARANÁ

VICTOR BRISK

**PREVISÕES DE VAZÃO DIÁRIA PARA A BACIA DO ALTO IGUAÇU COM O
EMPREGO DE REDES NEURAS ARTIFICIAIS DE FUNÇÃO DE BASE RADIAL**

CURITIBA

2016

VICTOR BRISK

**PREVISÕES DE VAZÃO DIÁRIA PARA A BACIA DO ALTO IGUAÇU COM O
EMPREGO DE REDES NEURAS ARTIFICIAIS DE FUNÇÃO DE BASE RADIAL**

Trabalho de conclusão de curso apresentado ao curso de Engenharia Ambiental da Universidade Federal do Paraná, como requisito para conclusão da disciplina Projeto Final II e requisito parcial para obtenção do título de Engenheiro Ambiental.

Orientador: Prof. Dr. Ricardo Carvalho de Almeida

CURITIBA

2016

TERMO DE APROVAÇÃO

VICTOR BRISK

PREVISÕES DE VAZÃO DIÁRIA PARA A BACIA DO ALTO IGUAÇU COM O EMPREGO DE REDES NEURAS ARTIFICIAIS RBF

Trabalho de conclusão de curso apresentado ao curso de Engenharia Ambiental da Universidade Federal do Paraná como requisito à obtenção do título de Engenheiro Ambiental, pela seguinte banca examinadora:

Prof. Dr. Ricardo Carvalho de Almeida
Orientador – UFPR/DEA

Prof. Dra. Cynara de Lourdes da Nóbrega Cunha
UFPR/DEA

Prof. Dr.Emílio Graciliano Ferreira Mercuri
UFPR/DEA

Curitiba, 03 de dezembro de 2016.

RESUMO

Este trabalho avaliou a capacidade de previsão de vazões diárias de uma rede neural do tipo Função de Base Radial (RBF) quando submetida a dados pretéritos de vazão e precipitação, para a bacia do Alto Iguaçu. O trabalho teve como objetivo comparar o desempenho de dois tipos de redes neurais artificiais: as redes RBF e Perceptron Multicamadas (MLP). Por fim, foi feito uma avaliação do desempenho da rede neural para vazões consideradas extremas. Foram utilizados dados de vazão e precipitação dos sítios *Hidroweb* e *Climate Prediction Center* (CPC), respectivamente. Adotou-se duas maneiras distintas para configurar os dados de entrada da RNA, sendo que uma configuração utilizou apenas dados de vazão pretérita e a outra utilizou dados de vazão e precipitação pretéritas. Para cada experimento realizado, variou-se o número de neurônios na camada oculta também, buscando encontrar a melhor configuração. Foram obtidos índices estatísticos para as fases de treinamento e operação das redes neurais em questão. O índice de Nash-Sutcliffe foi considerado como o índice de maior relevância para avaliar a acurácia dos modelos. Com base neste índice, a rede RBF mostrou-se ligeiramente melhor em todas as previsões, para a fase de operação. Os índices de qualidade obtidos ao avaliar as vazões extremas foram satisfatórios até o quinto horizonte de previsão.

Palavras-chave: Redes Neurais Artificiais, Previsão de vazões diárias, Nash-Sutcliffe.

LISTA DE FIGURAS

Figura 2.1- Representação simplificada do ciclo hidrológico	3
Figura 2.2 - Exemplificação do método de Thiessen	6
Figura 2.3 - Representação do neurônio biológico.....	8
Figura 2.4 - Representação esquemática do neurônio artificial.....	9
Figura 2.5 - Função Degrau	11
Figura 2.6 - Função Rampa	11
Figura 2.7 - Função Logística.....	12
Figura 2.8 - Função Gaussiana	13
Figura 2.9 - Função Linear	13
Figura 2.10 - RNA do tipo MLP com arquitetura feedfoward	15
Figura 2.11- RNA do tipo RBF	16
Figura 2.12- Classificação de padrões em uma rede RBF.....	18
Figura 2.13 - Representação de uma função de erros, contendo um mínimo local e um mínimo global	19
Figura 3.1 - Bacia do Alto Iguaçu	24
Figura 3.2 - Valores mensais de precipitação média na bacia do Alto Iguaçu.....	24
Figura 3.3- Valores mensais de vazão média na bacia do Alto Iguaçu	25
Figura 3.4 - Histograma de vazão.....	27
Figura 4.1 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de um dia.	33
Figura 4.2 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de dois dias.....	34
Figura 4.3 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de três dias.....	34
Figura 4.4 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de quatro dias.....	35
Figura 4.5 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de cinco dias.	35
Figura 4.6 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de seis dias.....	36
Figura 4.7 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de sete dias.....	36

Figura 4.8 - Erro do conjunto de treinamento do experimento P5Q9N5 para previsão com horizonte de 1 dia	37
Figura 4.9 - Diagrama de dispersão com horizonte de 1 dia, experimento P5Q9N5	40
Figura 4.10 - Diagrama de dispersão com horizonte de 1 dia, experimento Q3N20	40
Figura 4.11 - Curvas observada e prevista pelo modelo, no experimento P5Q9N5, com horizonte de 1 dia	41
Figura 4.12 - Curvas observada e prevista pelo modelo, no experimento Q3N20, com horizonte de 1 dia	41
Figura 4.13 - Diagrama de dispersão com horizonte de 2 dias, experimento P5Q7N10.....	42
Figura 4.14 - Diagrama de dispersão com horizonte de 2 dias, experimento Q3N25.....	42
Figura 4.15 - Curvas observada e prevista pelo modelo, no experimento P5Q7N10, com horizonte de 2 dias.....	43
Figura 4.16 - Curvas observada e prevista pelo modelo, no experimento Q3N25, com horizonte de 2 dias.....	43
Figura 4.17 - Diagrama de dispersão com horizonte de 3 dias, experimento P5Q7N20.....	44
Figura 4.18 - Diagrama de dispersão com horizonte de 3 dias, experimento Q3N5.....	44
Figura 4.19 - Curvas observada e prevista pelo modelo, no experimento P5Q7N20, com horizonte de 3 dias.....	45
Figura 4.20 - Curvas observada e prevista pelo modelo, no experimento Q3N5, com horizonte de 3 dias.....	45
Figura 4.21 - Diagrama de dispersão com horizonte de 4 dias, experimento P5Q9N20.....	46
Figura 4.22 - Diagrama de dispersão com horizonte de 4 dias, experimento Q3N20.....	46
Figura 4.23 - Curvas observada e prevista pelo modelo, no experimento P5Q9N20, com horizonte de 4 dias.....	47
Figura 4.24 - Curvas observada e prevista pelo modelo, no experimento Q3N20, com horizonte de 4 dias.....	47
Figura 4.25 - Diagrama de dispersão com horizonte de 5 dias, experimento P5Q7N20.....	48
Figura 4.26 - Diagrama de dispersão com horizonte de 5 dias, experimento Q3N15.....	48
Figura 4.27 - Curvas observada e prevista pelo modelo, no experimento P5Q7N20, com horizonte de 5 dias.....	49
Figura 4.28 - Curvas observada e prevista pelo modelo, no experimento Q3N20, com horizonte de 5 dias.....	49
Figura 4.29 - Diagrama de dispersão com horizonte de 6 dias, experimento P5Q7N5.....	50
Figura 4.30 - Diagrama de dispersão com horizonte de 6 dias, experimento Q3N10.....	50

Figura 4.31 - Curvas observada e prevista pelo modelo, no experimento P5Q7N5, com horizonte de 6 dias.....	51
Figura 4.32 - Curvas observada e prevista pelo modelo, no experimento Q3N10, com horizonte de 6 dias.....	51
Figura 4.33 - Diagrama de dispersão com horizonte de 7 dias, experimento P5Q9N10.....	52
Figura 4.34 - Diagrama de dispersão com horizonte de 7 dias, experimento Q3N10.....	52
Figura 4.35 - Curvas observada e prevista pelo modelo, no experimento P5Q9N10, com horizonte de 7 dias.....	53
Figura 4.36 - Curvas observada e prevista pelo modelo, no experimento Q3N10, com horizonte de 7 dias.....	53

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Tema	1
1.2	Objetivos	2
1.2.1	Objetivo Geral	2
1.2.2	Objetivos Específicos	2
2	REVISÃO BIBLIOGRÁFICA.....	3
2.1	PROCESSOS HIDROLÓGICOS	3
2.1.1	Ciclo Hidrológico	3
2.1.2	Precipitação	4
2.1.3	Interceptação.....	6
2.1.4	Evaporação e Evapotranspiração.....	6
2.1.5	Infiltração.....	6
2.1.6	Escoamento Superficial	7
2.2	Redes Neurais Artificiais	7
2.2.1	Neurônio biológico	7
2.2.2	Neurônio Artificial	9
2.2.3	Funções de ativação.....	10
2.2.3.1	Funções de ativação parcialmente diferenciáveis	10
2.2.3.2	Funções de ativação totalmente diferenciáveis.....	12
2.2.4	Arquiteturas de redes neurais artificiais	14
2.2.5	RNA do tipo Perceptron Multicamadas.....	14
2.2.6	Treinamento da RNA do tipo MLP	15
2.2.7	RNA do tipo Função de Base Radial.....	16
2.2.8	Treinamento da rede do tipo RBF	17
2.3	Aplicação de redes neurais em hidrologia	20
3	METODOLOGIA	23
3.1	Visão geral	23
3.2	Caracterização da bacia do Alto Iguaçu.....	23
3.3	Seleção e configuração dos dados de entrada da RNA.....	25
3.4	Treinamento e operação da RNA.....	27
3.5	Análise estatística dos resultados.....	30
4	RESULTADOS E DISCUSSÕES	31
4.1	Análise global dos resultados.....	31
4.1.1	Treinamento.....	31

4.1.2	Operação.....	38
4.2	Análise das vazões extremas.....	55
5	CONCLUSÃO	57
6	REFERÊNCIAS BIBLIOGRÁFICAS	59
	APÊNDICE A.....	62
	APÊNDICE B.....	78

1 INTRODUÇÃO

1.1 Tema

A água é provavelmente o único recurso natural que tem relação com todos os aspectos da civilização humana, desde o desenvolvimento agrícola e industrial aos valores culturais e religiosos arraigados na sociedade. É um recurso natural essencial, seja como componente bioquímico de seres vivos, como meio de vida de várias espécies vegetais e animais, como elemento representativo de valores sociais e culturais e até como fator de produção de vários bens de consumo final e intermediário. Assim, é de vital importância conhecermos a fundo o ciclo hidrológico, a fim de otimizar o uso deste recurso tão necessário para a manutenção da vida.

A determinação da vazão fluvial, em um determinado período, está associada a variáveis como evaporação, precipitação, transpiração etc. A estimativa da vazão é altamente complexa e de difícil previsão, considerando que há um grande número de variáveis incluídas. Além disso, as relações são não lineares. O conhecimento futuro da vazão tem diversas aplicações, como a previsão de enchentes urbanas ou de épocas de estiagem, abastecimento de água e geração de energia. O Brasil, por exemplo, gera 72,45% de sua energia elétrica através de aproveitamentos hidrelétricos, tornando-se vital ter acesso a estimativas de valores das futuras vazões, garantindo uma melhor otimização na produção de energia (ONS, 2016).

A previsão de vazão é baseada, principalmente, na modelagem chuva-vazão. Os primeiros modelos surgiram aproximadamente na década de 30, eram simples e desconsideravam a não linearidade dos processos hidrológicos. Esta situação foi contornada com o surgimento do computador, que é uma ferramenta capaz de processar um grande número de dados em um espaço de tempo relativamente curto, além disso, os desenvolvimentos teóricos possibilitaram a inclusão da não linearidade nos problemas envolvidos. Novos modelos foram denominados de modelos conceituais por considerarem, embora de maneira simples, os processos que ocorrem em uma bacia hidrográfica, como precipitação, infiltração, vazão e outras medidas hidrológicas (MACHADO, 2005). Atualmente, as previsões utilizadas como base pelo setor elétrico são fornecidas pelo Operador do Sistema Nacional Elétrico (ONS), o qual utiliza modelos estocásticos, do tipo auto regressivo periódico PAR, entre outros (FAYAL, 2008).

Com o surgimento de novas técnicas com a capacidade de resolver problemas não lineares, os chamados modelos de *Inteligência Artificial* (IA), criaram-se novos campos de

pesquisa que buscam desenvolver e aprimorar novos modelos hidrológicos. Um dos modelos de IA disponíveis são as *Redes Neurais Artificiais* (RNA's), baseadas no funcionamento do cérebro humano, de maneira mais simples, para realizar a transmissão e processamento de informações. As redes neurais conseguem representar problemas de alto grau de complexidade e são capazes de simular uma importante característica de processamento do cérebro humano, a generalização.

O trabalho a seguir apresenta uma revisão sobre os processos hidrológicos, além de explicar, de maneira superficial, como é a estrutura de uma rede neural artificial, retratando seu funcionamento e sua importância, além de indicar alguns trabalhos que já utilizaram redes neurais artificiais aplicadas na hidrologia. Em seguida, a metodologia do trabalho é exposta para que os resultados sejam entendidos de maneira mais clara e objetiva. Por fim, é apresentado um tópico contendo todos os resultados mais importantes e seus respectivos gráficos, seguido de um tópico final concluindo sobre os principais resultados encontrados no trabalho.

1.2 Objetivos

1.2.1 Objetivo Geral

Avaliar o desempenho de uma rede de função de base radial na previsão de vazões de curto prazo na bacia do Alto Iguaçu com horizonte de até sete dias.

1.2.2 Objetivos Específicos

- Avaliar o comportamento da rede neural artificial a partir da inserção de dados pretéritos de vazão e precipitação nos resultados de previsão de vazão obtidos por um modelo de RNA do tipo Função de Base Radial (RBF).

- Avaliar os resultados para a previsão de vazão, com horizonte de um a sete dias, para vazões globais e vazões extremas.

- Comparar qualitativamente os resultados obtidos pela rede RBF com a melhor configuração apresentada por CABRAL (2013) e discutir os resultados.

2 REVISÃO BIBLIOGRÁFICA

2.1 PROCESSOS HIDROLÓGICOS

2.1.1 Ciclo Hidrológico

O ciclo hidrológico abrange a circulação da água no planeta, tratando dos diversos caminhos e transformações em que ela é submetida na superfície terrestre e na atmosfera, os quais estão representados na figura 2.1. Este ciclo é impulsionado, fundamentalmente, pela energia solar associada à gravidade e a rotação terrestre (LINSLEY *et all*, 1975).

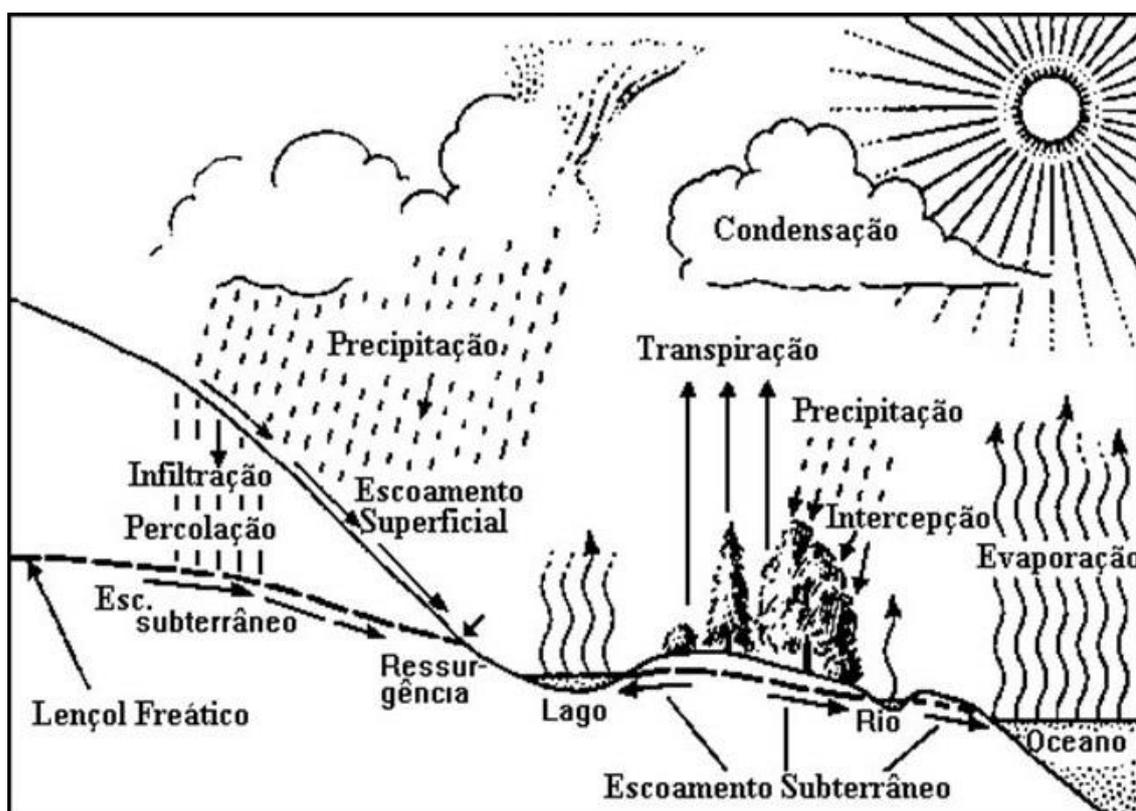


Figura 2.1- Representação simplificada do ciclo hidrológico

Fonte: BATISTA (2010)

Mesmo tratando-se de um ciclo contínuo e ininterrupto, é possível arbitrar a primeira etapa do ciclo como sendo a evaporação da água da superfície. O vapor da água assim formado é transportado para os continentes pelo movimento das massas de ar e, atendendo certas condições adequadas, sofre condensação e então precipita. Parte desta precipitação pode evaporar antes de tocar o solo ou ainda ser interceptada pela vegetação. A água que chega ao solo pode se tornar escoamento superficial, escoamento subsuperficial ou infiltrar e percolar até os aquíferos subterrâneos, os quais recarregam os rios e lagos constantemente. (LINSLEY *et all*, 1975).

Para um melhor entendimento dos processos hidrológicos utilizam-se os princípios básicos da mecânica dos fluidos, como o volume de controle, princípios da conservação de energia e conservação da massa. Podemos definir um sistema hidrológico como uma estrutura ou volume em determinado espaço, cercado por condições de contorno, o qual recebe água e outros elementos, operando internamente sobre eles e gerando um produto de saída (CHOW, 1988). A bacia hidrográfica é uma representação de um sistema hidrológico, onde os desníveis dos terrenos orientam os cursos d'água e determinam a bacia hidrográfica que se forma das áreas mais altas para as mais baixas. Ao longo do tempo, com a passagem da água da chuva vinda das áreas altas desgasta e esculpe o relevo no seu caminho, formando vales e planícies. A área de uma bacia é separada das demais por um divisor de águas, uma formação do relevo - em geral a crista das elevações do terreno - que separa a rede de drenagem (captação da água da chuva) de uma e outra bacia. De acordo com CHOW (1988), bacia hidrográfica ou bacia de drenagem é uma região sobre a terra, na qual o escoamento superficial em qualquer ponto converge para um único ponto fixo, o exutório. Assim, um exemplo de processo que ocorre na bacia é a transformação da precipitação (entrada) em vazão (saída).

2.1.2 Precipitação

Como precipitação entende-se toda a água que cai da atmosfera sobre a superfície terrestre, seja na fase sólida (neve e granizo) ou líquida (chuva).

A quantidade de precipitação é tipicamente expressa em milímetros ou polegadas, referindo-se ao volume precipitado por unidade de área. As medições são realizadas utilizando um pluviômetro. Existem diversos métodos utilizados para obter a média de precipitação h_m de uma bacia, neste trabalho serão apresentados os seguintes métodos: média aritmética, método das isoietas e triângulo de Thiessen.

O primeiro método é o mais simples dos três citados anteriormente. De acordo com a equação 2.1 para obter a precipitação média h_m , somam-se os valores de precipitações p_i obtidos nos postos pluviométricos e posteriormente divide-se a soma pela quantidade total de postos avaliados.

$$h_m = \frac{1}{n} \sum_{i=1}^n p_i \quad (2.1)$$

onde n é o número de postos pluviométricos analisados.

O método das isoietas é representado através de linhas curvas que representam pontos de igual pluviosidade. Tal como em um mapa topográfico onde as curvas de nível representam regiões de mesma cota (altura em relação a um referencial), as isoietas são curvas que delimitam regiões de mesma pluviosidade.

Para o cálculo da precipitação média da bacia por esse método, representado na equação 2.2, faz-se a média aritmética entre duas isoietas consecutivas e multiplica-se pela área entre as duas (A_i). Realiza-se este cálculo para todos os pares de isoietas da região demarcada e, posteriormente, somam-se os resultados obtidos. Por último, divide-se o resultado da soma anterior pela área total da bacia (A_t).

$$h_m = \frac{\sum_{i=2}^n \frac{P_{i-1} + P_i}{2} A_i}{A_t} \quad (2.2)$$

Por fim, a metodologia mais utilizada para calcular a precipitação média é a do método de Thiessen (figura 2.2). Este método subdivide a área da bacia em áreas delimitadas por retas unindo os pontos das estações, dando origem a vários triângulos. Traçando perpendiculares aos lados de cada triângulo, obtêm-se vários polígonos que encerram, cada um, apenas um posto de observação. Admite-se que cada posto seja representativo daquela área onde a altura precipitada é tida como constante. Cada estação recebe um peso pela área que representa em relação à área total da bacia. Se os polígonos abrangem áreas externas à bacia, essas porções devem ser eliminadas no cálculo. Portanto, obtêm-se a precipitação através da equação 2.3 onde a área total da bacia é representada por A_t e as áreas parciais por A_p , com as alturas precipitadas P_i .

$$h_m = \frac{\sum_{i=1}^n A_i P_i}{A_t} \quad (2.3)$$

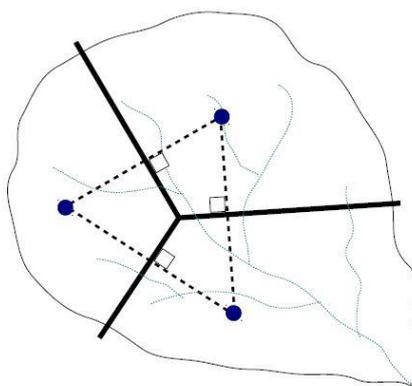


Figura 2.2 - Exemplificação do método de Thiessen

Fonte: CABRAL (2013)

2.1.3 Intercepção

A intercepção pode ser definida como parte do volume de água precipitado que fica retido na vegetação, ou seja, é a fração de água que não atinge o solo. Ainda, a intercepção depende de vários fatores, como as características das precipitações, das chuvas antecedentes, das condições climáticas, do tipo e densidade da floresta e da estação do ano (BLAKE, 1975).

2.1.4 Evaporação e Evapotranspiração

O processo físico pelo qual uma substância passa da fase líquida para a fase gasosa é chamado de evaporação. Transpiração é o processo pelo qual as plantas retiram umidade do solo e a liberam no ar sob a forma de vapor. Mais da metade da precipitação que cai sobre os continentes volta à atmosfera através da ação conjunta desses dois processos, denominada por evapotranspiração (KUMAR, 2008).

2.1.5 Infiltração

A infiltração é a penetração da água através da superfície do solo em direção ao subsolo. Após a passagem da água pela superfície do solo, ou seja, cessada a infiltração, a camada superior atinge um alto teor de umidade, enquanto que as camadas inferiores se apresentam ainda com baixos teores de umidade. Há então, uma tendência de um movimento descendente da água provocando um aumento do conteúdo de água nas camadas inferiores do solo, dando origem ao fenômeno que recebe o nome de redistribuição. Durante este processo, a água pode sofrer evaporação nas camadas superiores, verter para a superfície ao encontrar depressões ou percolar e alcançar o nível do aquífero, recarregando-o (LISNLEY *et al*, 1975).

A capacidade de infiltração de um solo é a velocidade máxima com que a água penetra no solo, sendo que este fator depende do tipo de solo avaliado, a permeabilidade, cobertura

vegetal e etc. Segundo CHOW (1988), quando a capacidade de infiltração do solo for conhecida, o volume de escoamento direto resultante de uma determinada chuva pode ser calculado subtraindo-se o volume infiltrado, e o retido na superfície (interceptação) do volume total da precipitação.

2.1.6 Escoamento Superficial

O escoamento superficial é a fase do ciclo hidrológico que resulta do excedente das águas precipitadas que não infiltraram ou evaporaram; e que escoam superficialmente pelo relevo indo nas direções das depressões, lagos, cursos d'água, e mares. Num segundo estágio, também é escoamento superficial o escoamento dos cursos d'água que são alimentados pela drenagem dos lençóis d'água subterrâneos. Para o engenheiro, a fase mais importante do ciclo hidrológico é a do escoamento superficial, pois a maioria dos estudos hidrológicos está ligada ao aproveitamento das águas superficiais e a proteção contra os efeitos provocados pelo seu deslocamento.

A principal característica de um evento chuvoso é o aumento da vazão dos rios. Através de um hidrograma, podemos representar graficamente a variação da vazão ao longo do tempo. O hidrograma observado após um evento chuvoso é o conhecido por hidrograma de cheia, sendo dividido em um alto gradiente de ascensão, um pico e um trecho de recessão (CARVALHO, 2003). Conclui-se, então, que o hidrograma pode ser entendido como resposta da bacia hidrográfica, em função de suas características fisiográficas que regem as relações entre chuva e escoamento de uma bacia hidrográfica a uma dada precipitação.

2.2 Redes Neurais Artificiais

Uma rede neural artificial é um modelo altamente complexo, não-linear, capaz de resolver problemas de natureza diversa, ser treinado e adaptar conhecimentos de problemas já conhecidos para situações semelhantes. Logo, podemos dizer que as Redes Neurais possuem uma alta capacidade de generalização. A fonte de inspiração para construção deste modelo tem como base o funcionamento do cérebro humano. Assim, a compreensão do funcionamento de uma rede neural biológica serve como fundamentação para o melhor entendimento de uma rede neural artificial.

2.2.1 Neurônio biológico

A principal célula do sistema nervoso central é o neurônio e o seu objetivo principal é conduzir estímulos elétricos advindos de reações físico-químicas (impulsos) sob condições

ideais de funcionamento. Divide-se o neurônio em três partes principais: O dendrito, o corpo celular ou soma, e o axônio (HAYKIN, 2001).

Os dendritos são constituídos por diversos prolongamentos que formam a árvore dendrital, de acordo com a figura 2.3. Os dendritos realizam a função de captar, de forma contínua, os estímulos que partem de outros neurônios próximos. O corpo celular é incumbido de processar todas as informações advindas dos dendritos a fim de produzir um potencial de ativação que indicará se o neurônio poderá disparar um impulso elétrico ao longo de seu axônio. Dentro do corpo celular encontram-se as principais organelas citoplasmáticas como o núcleo e a mitocôndria do neurônio. Por fim, tem-se o axônio que é constituído por um único prolongamento com a função de conduzir os impulsos elétricos gerados para outros neurônios (SILVA *et all*, 2010).

A transmissão de um neurônio para o outro é denominada sinapse. As sinapses podem ser elétricas ou químicas, e cada neurônio realiza milhares de sinapses por segundo. Na sinapse química, há a secreção de uma substância transmissora, conhecida como neurotransmissor, pelo primeiro neurônio, a qual irá atuar em proteínas receptoras do neurônio subsequente, podendo ter ação excitatória ou inibitória.

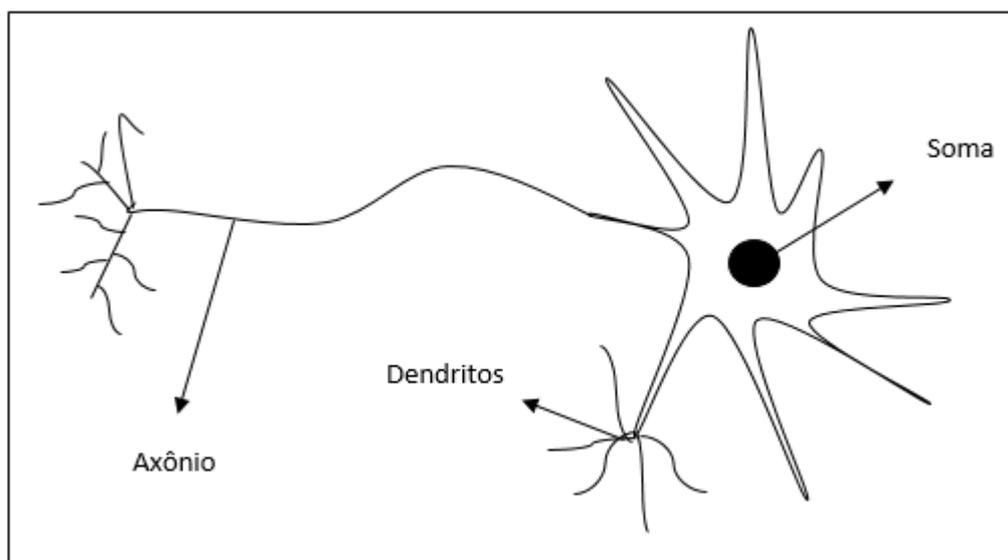


Figura 2.3 - Representação do neurônio biológico

Fonte: Autor

Os neurotransmissores reagem com as proteínas receptoras do neurônio pós-sináptico, gerando uma polarização ou despolarização da membrana celular do neurônio. Assim, gera-se

um impulso elétrico que é propagado ao longo do axônio. Já nas sinapses elétricas, existe uma transferência de íons entre as células nervosas. As sinapses químicas possuem uma característica importante para a transmissão de informações no cérebro, elas são unidirecionais, enquanto que as transmissões das sinapses elétricas podem ocorrer em ambos os sentidos (CARDOSO, 2016 ; NITRINI e BACHESCHI, 2008).

2.2.2 Neurônio Artificial

O neurônio artificial, representado na figura 2.4, é uma analogia ao neurônio biológico. Pode-se dizer que as ligações representam os axônios e dendritos, os pesos simbolizam o potencial elétrico das sinapses e o processamento dentro da unidade representa a atividade do corpo celular. Estes neurônios, utilizados em modelos de redes neurais artificiais, fornecem saídas contínuas e realizam funções simples, como coletar os sinais existentes das entradas e, após processá-los, enviar uma resposta dependendo da função de ativação existente.

O primeiro modelo de neurônio artificial foi proposto por McCulloch&Pitts (1943) englobando as principais características de uma rede neural biológica. Ainda hoje é um dos modelos mais utilizados em diferentes arquiteturas de redes neurais artificiais.

Tendo em vista a figura 2.4, pode-se verificar que o funcionamento da rede artificial abrange os seguintes elementos principais (HAYKIN, 2001):

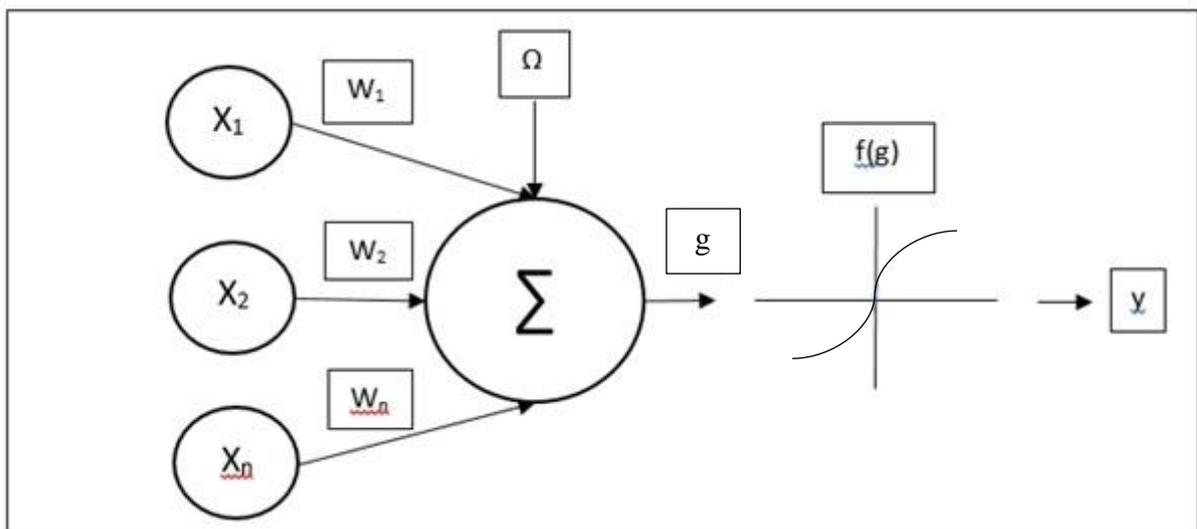


Figura 2.4 - Representação esquemática do neurônio artificial

Fonte: Autor

- 1) Pesos sinápticos: O conjunto de pesos ponderados $\{w_1, w_2, \dots, w_n\}$ está relacionado com as ponderações exercidas pelas junções sinápticas do modelo de neurônio biológico. A relevância de cada uma das entradas $\{x_i\}$ é definida por meio de multiplicações por seus respectivos pesos $\{w_i\}$, ponderando-se todas as informações externas fornecidas para o neurônio artificial.
- 2) Combinador linear: Usualmente representado por $\{\Sigma\}$, a sua função é congrega todos os sinais de entrada $\{x_i\}$ já ponderados pelos seus respectivos pesos sinápticos $\{w_i\}$ com a intenção de produzir um valor de potencial de ativação.
- 3) Limiar de ativação: A variável $\{\Omega\}$ especifica qual será o limite apropriado para que o resultado produzido pelo combinador linear possa gerar um valor de disparo em direção à saída do neurônio artificial.
- 4) Potencial de Ativação: Representado por $\{u\}$, define se o neurônio artificial irá produzir um potencial excitatório ($u \geq 0$) ou inibitório ($u < 0$). Este resultado é gerado pela diferença entre os valores do combinador linear e o limiar de ativação.
- 5) Função de Ativação: A função $\{G\}$ limita a saída do neurônio artificial dentro de um intervalo de valores. São diretamente responsáveis pela determinação de cada resposta do neurônio.
- 6) Sinal de Saída: Consiste no valor final $\{y\}$ produzido pela atividade total no neurônio em relação ao conjunto de entradas previamente apresentado.

Assim, podemos expressar o resultado do modelo de neurônio artificial proposto por McCulloch&Pitts (1943) através das seguintes relações:

$$u = \sum_{i=1}^n w_i x_i - \Omega \quad (2.4)$$

$$y = g(u) \quad (2.5)$$

2.2.3 Funções de ativação

As funções de ativação podem ser divididas em dois grupos. As funções parcialmente diferenciáveis são aquelas que possuem pontos onde a derivada de primeira ordem não existe. Já as funções totalmente diferenciáveis possuem derivada de primeira ordem em todos os pontos de seu domínio. Seguem-se alguns exemplos destas funções.

2.2.3.1 Funções de ativação parcialmente diferenciáveis

a) Função Degrau

Quando o potencial de ativação do neurônio for maior ou igual a zero, o resultado dado pela função degrau assumirá valores unitários positivos. Caso contrário, o resultado terá valores nulos. A figura (2.5) mostra um exemplo de uma função degrau.

$$f(x) = \begin{cases} 1, & \text{se } x \geq 0 \\ 0, & \text{se } x < 0 \end{cases} \quad (2.6)$$

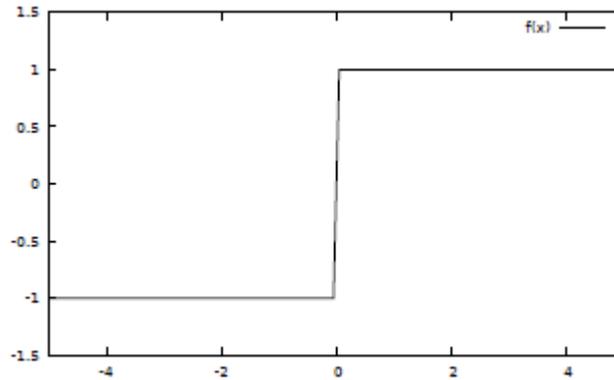


Figura 2.5 - Função Degrau

Fonte: CABRAL (2013)

b) Função rampa simétrica

Os valores produzidos são iguais aos valores dos potenciais de ativação quando estes pertencem ao intervalo $[-x,x]$, como pode ser observado na figura 2.6.

$$f(x) = \begin{cases} 1, & \text{se } x > b \\ x, & \text{se } |x| < b \\ -1, & \text{se } x < -b \end{cases} \quad (2.7)$$

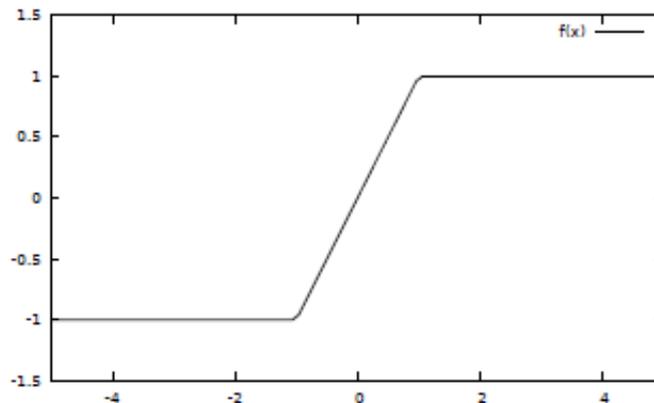


Figura 2.6 - Função Rampa

Fonte: CABRAL (2013)

2.2.3.2 Funções de ativação totalmente diferenciáveis

a) Função Logística

Dada pela relação matemática:

$$g(u) = \frac{1}{1 + e^{-\beta u}} \quad (2.8)$$

Onde β é uma constante real relacionada com a inclinação da função logística em relação ao seu ponto de inflexão. Os valores produzidos pelo uso desta função serão sempre entre zero e um. A figura (2.7) é um exemplo de função logística.

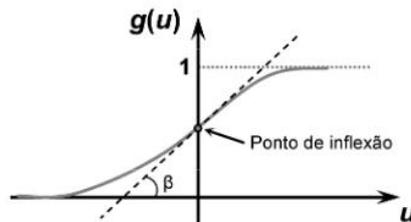


Figura 2.7 - Função Logística

Fonte: SILVA *et al.*, 2010

b) Função gaussiana

A saída do neurônio produzirá resultados iguais para os valores de potencial de ativação $\{u\}$ que estejam posicionados a uma mesma distância de seu centro (média), sendo que a curva é simétrica a este. Uma das aplicabilidades da função gaussiana acontece nas redes neurais de função de base radial, como será visto nos capítulos seguintes. Ela é definida da seguinte forma:

$$g(u) = e^{-\frac{(u - c)^2}{2\sigma^2}} \quad (2.9)$$

onde c é um parâmetro que define o centro da função gaussiana e σ^2 expressa o quão disperso a curva está em relação ao seu centro (variância) (HALDAR E MAHADEVAN, 2000). A figura (2.8) é um exemplo de função gaussiana.

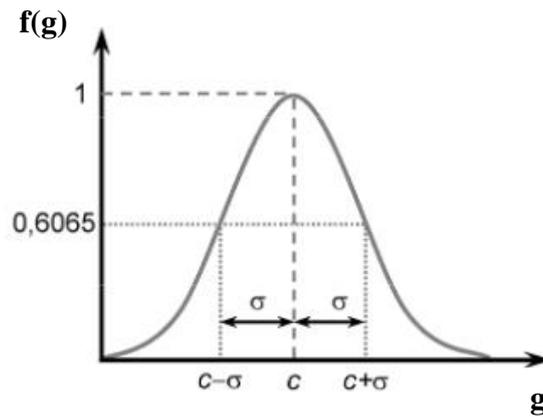


Figura 2.8 - Função Gaussiana

Fonte: SILVA *et al*, 2010

c) Função linear

Conhecida também como função identidade, os valores de potencial de ativação serão iguais aos resultados de saída produzidos, e é dada por:

$$g(u) = u \quad (2.10)$$

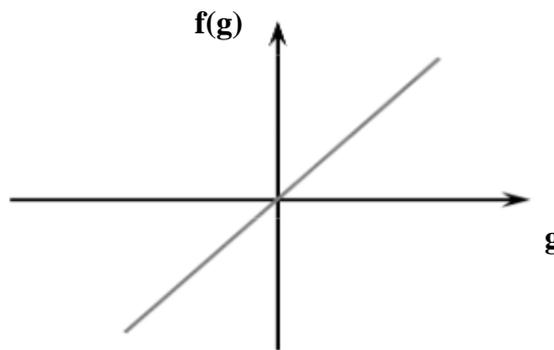


Figura 2.9 - Função Linear

Fonte: SILVA *et al*, 2010

A função de ativação linear é muito utilizada nas redes neurais artificiais que aproximam uma função que relacione as variáveis de entrada e saída nos processos (BRAGA *et all*, 2011). A figura (2.9) é um exemplo de função linear.

2.2.4 Arquiteturas de redes neurais artificiais

A arquitetura de uma rede neural artificial define como os neurônios artificiais estão arrançados uns em relação aos outros. Estes arranjos estruturam-se de acordo com o direcionamento das conexões sinápticas dos neurônios. Assim, para uma certa arquitetura, uma rede neural pode assumir diversas formas de composição.

Diferentes tipos (arquiteturas) de redes neurais são obtidos variando-se o tipo de neurônio utilizado, a função de ativação dos neurônios e o modo de conexão entre os diversos neurônios. Assim, dentre as principais arquiteturas de redes neurais artificiais, pode-se mencionar a Perceptron de Multicamadas (MLP) e a rede de Função de Base Radial (RBF).

CABRAL (2013), utilizou a rede perceptron multicamada para realizar seu estudo sobre modelagem chuva-vazão da bacia do Alto Iguaçu. Portanto, uma breve explicação deste tipo de arquitetura se faz necessário para uma melhor avaliação deste trabalho.

2.2.5 RNA do tipo Perceptron Multicamadas

A rede MLP (*Multilayer Perceptron*) é baseada no modelo perceptron proposto por ROSENBLATT (1958). Por apresentar apenas uma camada, a utilização do perceptron é viável apenas para problemas linearmente separáveis. Entretanto, o uso de uma ou mais camadas intermediárias, permite a uma rede neural a aproximação de qualquer função (CYBENKO, 1989). A Figura 2.10 mostra um exemplo de uma rede perceptron multicamadas, tipicamente formada por uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída. A arquitetura é do tipo *feedforward*, o que significa que o fluxo de informação ocorre da entrada para a saída. Cada neurônio da camada de entrada está conectado a todos os neurônios da camada oculta e estes neurônios, por sua vez, estão conectados com os neurônios da camada de saída. Entre as conexões da rede são introduzidos pesos que tem como objetivo simular o conhecimento sobre o problema estudado. Para reduzir os erros, a rede deve passar por um processo de treinamento.

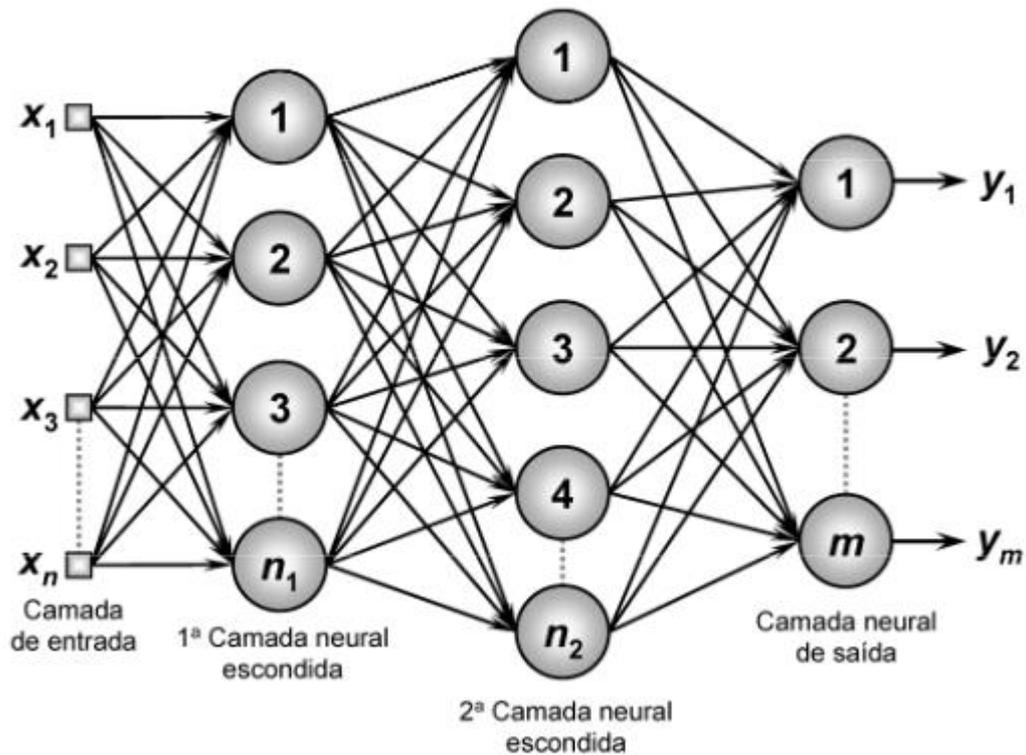


Figura 2.10 - RNA do tipo MLP com arquitetura feedforward

Fonte: SILVA *et al*, 2010

2.2.6 Treinamento de uma RNA

Para que uma RNA apresente o melhor resultado possível é necessário que ela seja capaz de aprender com estímulos externos. Assim, é necessário treinar a rede. Para tal tarefa existem diversos algoritmos já desenvolvidos, os quais diferem entre si na maneira como os pesos são reajustados ao longo do treinamento. O treinamento pode ser dividido em duas categorias: supervisionado, não supervisionado (FRITSCH e GÜNTHER, 2010).

O treinamento supervisionado trabalha com pares de dados de entrada e saída. Para toda entrada apresentada à RNA, uma saída será produzida. Quando a diferença entre a saída processada pela rede e o valor de saída de referência forem diferentes, os pesos entre as conexões são ajustados. Este processo é repetido até que se encontre um erro satisfatório. No caso do treinamento não supervisionado, os valores de referência não são fornecidos. Assim, a própria rede deve se organizar para classificar os resultados encontrados. O resultado obtido pela RNA recebe uma espécie de nota conforme o quão acurado é, assim os pesos são ajustados de acordo.

Dentre estas formas de treinamento, é utilizado nas redes MLP o treinamento supervisionado com a utilização de um algoritmo, conhecido como *backpropagation*. Esta técnica pode ser dividida em duas fases: *forward* e *backward*. A fase *forward* calcula o valor de saída da rede para o padrão de entrada e a fase *backward* atualiza os pesos das conexões dos nós da rede a partir do erro de saída (BRAGA *et al*, 2011).

2.2.7 RNA do tipo Função de Base Radial

A rede denominada função de base radial, também conhecida como RBF (*radial basis function*) pode ser aplicada em todos os problemas tratados pelo MLP. A RBF é do tipo multicamadas e *feedforward*, o que significa que a arquitetura da rede é disposta com diversas camadas e o fluxo de informação ocorre da entrada para a saída. Uma arquitetura básica de RBF contém uma camada de entrada, uma única camada escondida e uma camada de saída, de acordo com a figura 2.11. A primeira camada consiste nos neurônios que recebem os dados de entrada. A segunda camada é responsável por tratar os dados de entrada utilizando uma função não-linear do tipo gaussiana dentro dos neurônios. Por fim, a última camada é encarregada de transformar os valores recebidos por meio de funções de ativação. No caso de aproximação de funções, são funções são lineares (HAYKIN, 2001).

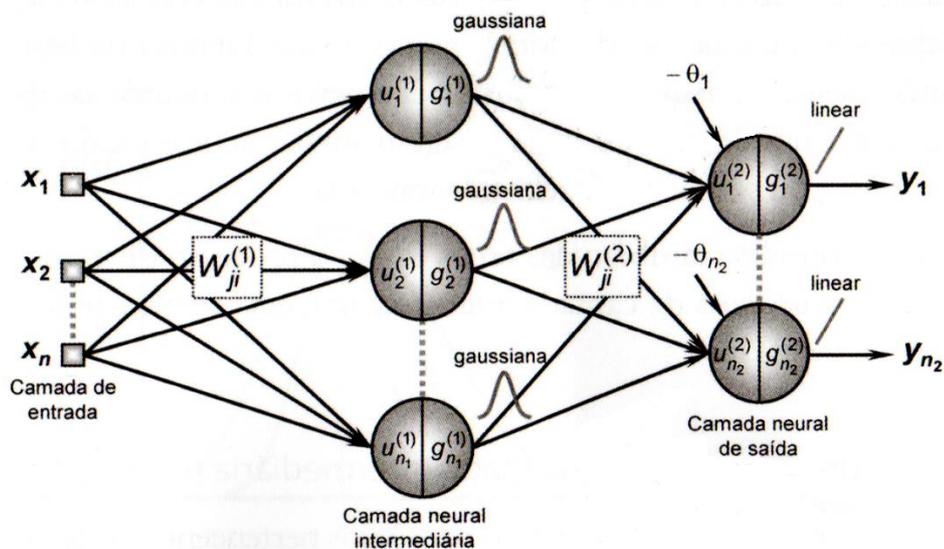


Figura 2.11- Ilustração das camadas de uma RNA do tipo RBF

Fonte: SILVA et al, 2010

2.2.8 Treinamento da rede do tipo RBF

Diferentemente da rede MLP, a rede RBF possui duas fases distintas de treinamento. A primeira fase trata do treinamento na camada oculta da rede, enquanto que a segunda fase do treinamento se dá na camada de saída, como definida a seguir:

a) Ajuste dos neurônios na camada oculta: Como mencionado antes, os neurônios da camada intermediária, ou oculta, são compostos por funções não lineares do tipo gaussianas, sendo definidas pela equação 2.9. A figura 2.8 ilustra o formato geométrico de uma função gaussiana típica. Deve-se ajustar os parâmetros que definem o centro c e a variância σ^2 , sendo que quanto maior o valor adotado para a variância, mais alargada será a base da função. Ademais, quanto mais próxima do centro de uma gaussiana uma amostra qualquer estiver, mais significativa será o valor produzido pelo campo receptivo radial da função de ativação. Levando em conta a figura 2.11, além da configuração dos neurônios da camada oculta, nota-se que o centro c está diretamente ligado aos seus próprios pesos. Logo, a entrada $u_j^{(1)}$ de cada um será o próprio vetor de entrada x , que representa os n sinais externos que a rede recebe. Então, segundo SILVA *et all* (2010), a saída de cada neurônio j da camada intermediária é dada por:

$$g_j^{(1)}(u_j^{(1)}) = g_j^{(1)}(x) = e^{\frac{-\sum_{i=1}^n (x_i - w_{ij}^{(1)})^2}{2\sigma_j^2}} \quad (2.11)$$

onde o expoente (1) representa a conexão entre a camada de entrada e a camada oculta. À vista disso, o objetivo dos neurônios na camada oculta é posicionar os centros de suas gaussianas da melhor forma possível. Para isso, um algoritmo muito comum é o *k-means*, também conhecido como *clustering*, que tem como objetivo definir k -gaussianas (onde k é o número de neurônios na camada oculta) cujos centros tendem a se posicionar em regiões onde os padrões de entrada tenderão a se agrupar. Quanto mais próxima esteja a amostra do centro agrupamento, mais significativa será o valor da resposta do campo receptivo gaussiano. A figura 2.12 representa um problema de treinamento qualquer constituído de duas entradas X_1 e X_2 com amostras quaisquer de treinamento, contendo dois neurônios na camada oculta (DUDA *et all*, 2001)

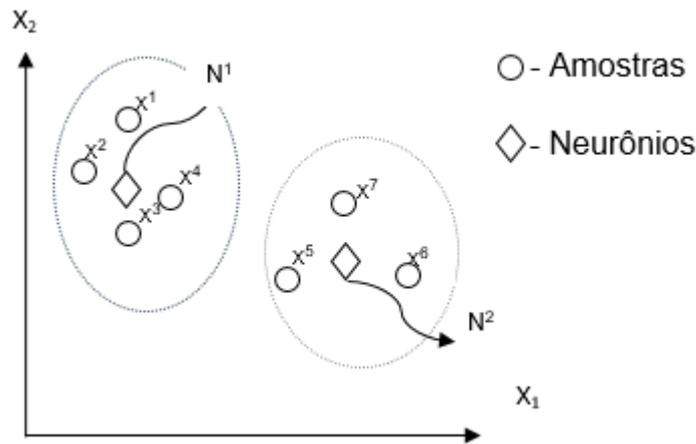


Figura 2.12- Classificação de padrões em uma rede RBF. X_i representa amostras quaisquer e N^j representam os neurônios na camada oculta

Fonte: Autor

b) Ajuste dos neurônios na camada de saída: A segunda fase do treinamento só tem início quando o ajuste do agrupamento (*clustering*) for completado. Além do mais, este estágio de treinamento tem uma grande semelhança com o treino das redes MLP, utilizando-se de um método de aprendizagem supervisionada.

De acordo com a figura 2.11 o conjunto de treinamento para os neurônios da camada de saída será formado por pares de entrada e saída, sendo que as entradas são os valores enviados pelas funções de ativação gaussianas, localizadas nos neurônios da camada oculta, em resposta as amostras de treinamento. O índice (2) corresponde a conexão entre a camada oculta e a camada de saída da rede neural. Assim, tem-se a seguinte formulação (SILVA *et al*, 2010):

$$u_j^{(2)} = \sum_{i=1}^n w_{ji}^{(2)} g_j^{(1)}(u_i^{(1)}) - \theta_j, \text{ onde } j = 1, \dots, n \quad (2.12)$$

sendo que $W_{ij}^{(2)}$ e θ_j são os pesos e limiares referentes aos neurônios das camadas de saída.

Por fim, uma função linear é adotada como função de ativação para atuar na camada de saída da RBF, de acordo com:

$$y_j = g_j^{(2)} u_j^{(2)} = u_j^{(2)}, \text{ onde } j = 1, \dots, n \quad (2.13)$$

Após vários ciclos de treinamento, a rede terá aprendido sobre o problema apresentado, com um ajuste de pesos otimizados. Porém, apesar de capacidade de aproximação a qualquer função, uma rede MLP não garante a implementação da função. Dependendo da distribuição dos dados, a rede pode convergir para uma solução não satisfatória ou pode demorar mais para convergir. O ajuste de pesos otimizados corresponde a uma combinação de pesos que leva o

menor erro possível, erro este que pode ser representado em uma função de erro $h(x)$, de acordo com a figura 2.13.

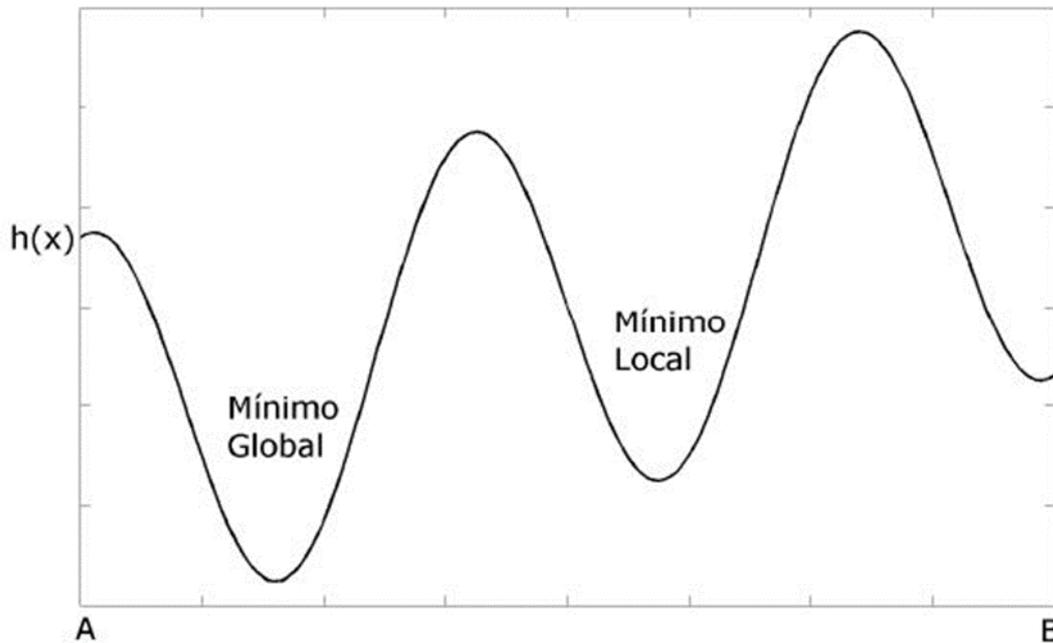


Figura 2.13 - Representação de uma função de erros, contendo um mínimo local e um mínimo global

Pode existir mais de um mínimo local, além do mínimo global, sendo que o treinamento busca justamente encontrar este mínimo global. Quando qualquer um destes mínimos locais é reconhecido como um mínimo global, haverá um falso ajuste dos pesos, levando a uma solução pouco satisfatória. Além disto, um segundo problema que pode ser encontrado na rede é o *overtraining*, ponto no qual a rede memoriza o problema devido ao excesso de treinamento, tornando-se excessivamente especializada, perdendo sua capacidade de generalizar.

Para realizar o aprendizado é necessário um conjunto de dados pretéritos, os quais já possuam resultados conhecidos associados a eles. Então, estes dados são divididos em grupos de treinamento, teste e validação da rede. Segundo HSU *et al.*, (1995), adota-se a seguinte classificação:

- a) Treinamento: Este grupamento guarda a maior quantidade de dados históricos, dentre os três grupamentos citados. Também, deve conter uma parcela significativa das séries históricas, levando em conta todas as variações ocorridas ao longo dos anos.
- b) Teste: Após cada época de treinamento, uma pequena parcela de dados é apresentada a RNA, visando estimar o valor do erro. A cada treinamento, o erro do conjunto de teste tende a ser menor, buscando o ponto ótimo desejado. Quando o erro do conjunto de teste passa a aumentar,

chegou-se a condição de *overtraining*, quando a rede memoriza o problema e perde a capacidade de generalizar.

c) Validação: A validação acontece quando o melhor ajuste para o conjunto de pesos é encontrado. A parcela de dados históricos ainda não utilizados para treinamento e teste serão então apresentados a rede. Por fim, os valores obtidos pela rede serão comparados com os resultados verdadeiros, demonstrando-se o quanto a rede aprendeu e qual é a qualidade de seu treinamento.

2.3 Aplicação de redes neurais em hidrologia

O processo que transforma chuva em vazão tem elevada importância na área de recursos de hídricos. Então, a avaliação quantitativa desse processo permite o melhor gerenciamento dos diversos usos da água. Porém, como já mencionado antes, os processos hidrológicos em geral são não lineares. Assim, surge a aplicabilidade dos modelos baseados em redes neurais artificiais.

CABRAL (2013) apresentou uma aplicação de redes de neurais MLP, com dados pretéritos de vazão e precipitação, para a previsão da vazão diária da bacia do Alto Iguaçu. Segundo a autora do trabalho, foram feitas previsões para um horizonte de até 7 dias, sendo que os resultados foram satisfatórios e muitas vezes superaram em acurácia os valores encontrados na literatura.

KUMAR *et al* (2008) apresentaram um estudo avaliando o desempenho global das redes MLP e RBF para a modelagem chuva-vazão de duas bacias hidrográficas indianas. Tanto o desempenho da rede MLP e RBF foram exaustivamente avaliados em termos de suas propriedades de generalização. Os resultados do estudo indicam que a escolha do tipo de rede certamente tem um impacto sobre a acurácia do modelo. O estudo sugere que ambas as redes têm méritos e limitações. Por exemplo, o MLP requer um extenso processo de tentativa e erro para fixar o número ótimo de neurônios na camada intermediária, enquanto que para uma RBF a estrutura da rede pode ser fixa desde que se utilize um algoritmo de treinamento adequado. No entanto, um julgamento de qual rede é superior não foi apresentado.

No trabalho de IRWAN *et al.* (2007) foi feita a aplicação da rede MLP e da rede RBF para prever a vazão diária em função da precipitação para as seguintes bacias hidrográficas localizadas na Malásia: Sungai Lui, Sungai Klang, Sungai Bekok, Sungai Slim e Sungai Ketil. Os dados utilizados consistiram em dois conjuntos: quatro anos foram utilizados para o treinamento das RNA's um ano de dados foram utilizados para validação do modelo. O desempenho de cada modelo foi avaliado utilizando o coeficiente de eficiência, o erro médio

quadrado, o erro médio absoluto e a média relativa. O estudo revelou que as redes RBF exibiam consistentemente um melhor desempenho em comparação com a rede MLP. Mais ainda, a vantagem da rede RBF, segundo os autores, é que ela pode ser treinada muito mais rapidamente que a rede MLP.

MACHADO (2005) utilizou RNAs para modelar a relação entre chuva e vazão para a bacia hidrográfica do rio Jangada, no estado do Paraná. As RNAs foram capazes de identificar a relação chuva-vazão satisfatoriamente e apresentaram melhores resultados que os calculados por um modelo conceitual.

HARPHAM e WILBY (2006) aplicaram três métodos de regionalização, duas arquiteturas de RNA e um método estatístico, para prever máximas diárias de precipitação na região noroeste da Inglaterra e o norte do país de Gales (região NWE) e no sudeste da Inglaterra (região SEE). Os dados foram obtidos de uma rede de 15 estações na área da região NWE e de 28 estações na área da região SEE. Os dados usados como preditores são do projeto Reanalysis e o método usado para seleção de preditores foi o de regressão linear múltipla. Os três métodos de regionalização utilizados foram: RNA de Múltiplas Camadas (MLP), RNA do tipo Radial Basis Function (RBF) e um modelo de reamostragem condicional. Um dos objetivos do trabalho era verificar a capacidade das RNAs para prever eventos extremos de precipitação diária. Nenhum dos três modelos conseguiu prever satisfatoriamente todos os índices extremos de eventos, entretanto os melhores resultados para previsão do número de dias consecutivos sem chuva foi realizada pelas RNAs.

SANTOS (2001) cita um estudo em que se fez uma análise da aplicação de RNAs do tipo MLP na simulação de transformação de chuva em vazão e na previsão de vazões médias mensais. Os resultados obtidos com redes neurais foram comparados com resultados obtidos de modelos tradicionais utilizando-se as vazões médias calculadas. Utilizaram-se para análise dos resultados o coeficiente de correlação entre vazões obtidas e observada e o erro percentual médio absoluto das previsões. O estudo concluiu que a grande vantagem da técnica de RNA está na sua versatilidade de permitir, na modelagem do processo chuva-vazão, incorporação da representatividade de cada posto pluviométrico em vez de se trabalhar com chuva média. Outro aspecto foi a possibilidade de considerar a regionalização levando-se em conta aspectos diversos da bacia, tais como: área da bacia, declividade, pluviometria média, coeficientes de forma da bacia, tipo de solo, etc. Na previsão mensal de vazão os resultados também comprovaram a eficácia da técnica de RNA.

Por fim, observou-se que a maioria dos estudos que envolvem redes neurais artificiais são feitos com as redes MLP. Assim, existe poucos trabalhos que usam aplicação de redes RBF, em hidrologia, o que ressalta ainda mais importância de estudar estes tipos de rede.

3 METODOLOGIA

3.1 Visão geral

A metodologia deste trabalho será baseada no estudo de CABRAL (2013). A área de estudo e os dados hidrometeorológicos a serem utilizados são os mesmos do estudo realizado por aquela autora.

3.2 Caracterização da bacia do Alto Iguaçu

O rio Iguaçu é formado a partir do encontro dos rios Atuba e Irai e em Curitiba recebe o nome de Iguaçu. É conhecido como o rio dos três municípios, porque seu marco zero divide os municípios de Curitiba, Pinhais e São José dos Pinhais. Na sua foz é conhecido como o rio dos três países, dividindo o Brasil, o Paraguai e a Argentina. Este rio abastece Curitiba e várias outras cidades até sua foz, possuindo 910 km de extensão e uma área de drenagem de 65558 km² em sua totalidade (SUDERHSA, 2007). Ele recebe as águas de todos os rios de Curitiba, apresentando inúmeros afluentes. Os principais são os rios formadores das cinco sub-bacias da cidade são: o rio Passaúna, o rio Barigui, o Rio Belém, o Ribeirão dos Padilhas e o rio Atuba. A bacia do Iguaçu é subdividida em cinco unidades menores, sendo a primeira a sub-bacia do Alto Iguaçu, área de estudo deste trabalho contemplada na figura 3.1, com uma área de 6382 km² (SUDERHSA,2007).

O estado do Paraná tem como característica o clima subtropical úmido, sendo que a bacia do Alto Iguaçu tem chuvas bem distribuídas ao longo do ano. No inverno, o regime de chuvas é influenciado pelo movimento de massas de ar polar marítimo, associadas à presença de centros de baixa pressão. Denomina-se como precipitação do tipo frontal quando existe o encontro dessas massas frias com massas de ar mais quentes, sendo recorrentes na bacia que é o foco do estudo deste trabalho. De acordo com o trabalho de CABRAL (2013), as bacias do Alto Paraná e Alto Ribeira foram tomadas como uma unidade conjunta, a fim de unificar os postos pluviométricos da região para uma melhor análise. Assim, de acordo com o relatório apresentado pela SUDERHSA (2007), foi possível extrair os valores mensais de precipitação média e vazão média na bacia do Alto Iguaçu, representando nas figuras 3.2 e 3.3 respectivamente, fornecendo uma ideia do regime de chuvas da bacia estudada.

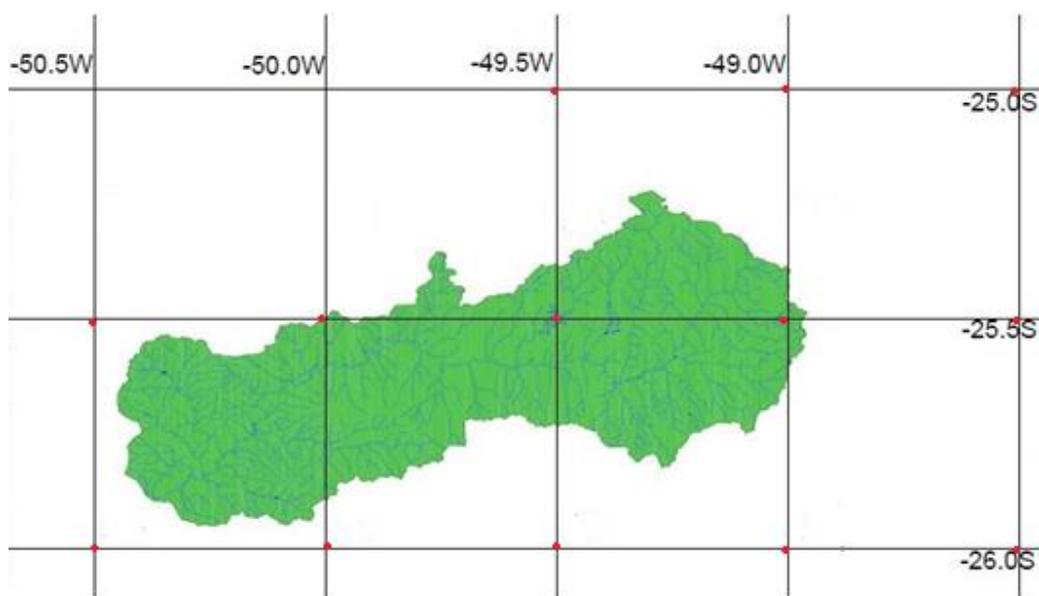


Figura 3.1 - Bacia do Alto Iguaçu e pontos de precipitação do CPC.

Fonte: CABRAL (2013)

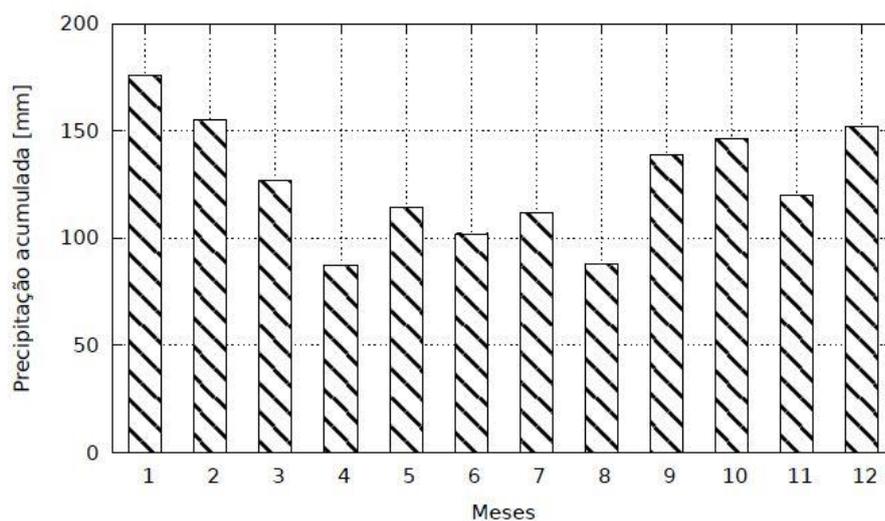


Figura 3.2 - Valores mensais de precipitação média na bacia do Alto Iguaçu

Fonte: CABRAL (2013)

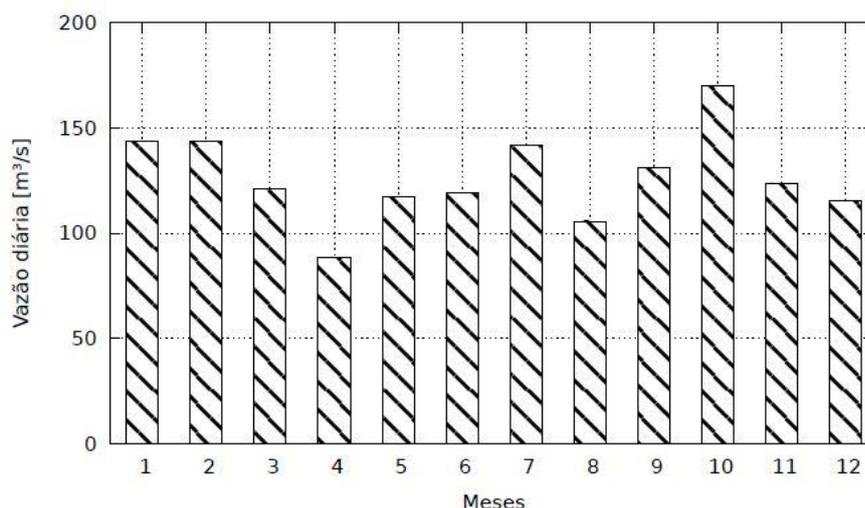


Figura 3.3- Valores mensais de vazão média na bacia do Alto Iguaçu

Fonte: CABRAL (2013)

3.3 Seleção e configuração dos dados de entrada da RNA

Como mencionado anteriormente, o objetivo deste trabalho é comparar o desempenho da rede MLP utilizada por CABRAL (2013), com o desempenho de uma rede RBF. Sendo assim, os dados de entrada (precipitação e vazão pretéritas) utilizados em ambos os trabalhos são os mesmos, para fins de comparação. A base de dados de vazão pertence ao posto fluviométrico localizado no município de São Mateus do Sul. A razão pela qual este posto foi escolhido vem da disponibilidade de dados contendo uma série de histórica mais completa e de melhor qualidade.

De acordo com CABRAL (2013), os dados de precipitação foram obtidos no sítio do *Climate Prediction Center* (CPC, 2013). Na figura 3.1 os pontos de grade indicados em vermelho representam as médias de precipitação do CPC empregadas no método de Thiessen. Como o modelo numérico de geração de dados de precipitação fornece dados apenas a partir do ano de 1979, a série histórica de precipitação utilizada para executar a rede neural foi definida para o intervalo entre os anos de 1979 e 2005.

Para os dados de vazão diária observados no posto de São Mateus do Sul, foi utilizada a base de dados do sítio *Hidroweb* (2013). As observações situam-se entre 1935 até o ano de 2010, porém existe um período de dados incompletos entre os anos de 2006 e 2009. Logo, para manter a uniformidade entre os dados de precipitação e vazão, o intervalo a ser utilizado no

treinamento da rede neural foi redefinido entre os anos de 1979 até 2003. Os dados referentes ao período de 2003 até 2005 foram reservados para posterior operação da rede neural.

Os dados de entrada foram apresentados a rede neural seguindo duas configurações diferentes. Na primeira configuração, foram apresentados apenas dados de vazão pretérita. Já na segunda configuração, foram agregados os dados de precipitação pretéritos, após a realização da média ponderada dos valores, seguindo o método de Thiessen.

Antes de inserir os dados de entrada na rede neural artificial, é necessário que haja uma normalização de todos os dados para evitar que a rede seja afetada por valores muito discrepantes da média. Essencialmente, os dados devem ficar contidos em um intervalo entre -1 e 1. Para tanto, as seguintes formulações são utilizadas:

$$x_n = \frac{2(x - x_{\min})}{x_{\max} - x_{\min}} - 1 \quad (3.1)$$

$$x = \frac{x_{\max} + x_{\min}}{2} \quad (3.2)$$

onde x_n é o valor normalizado, x_{\min} e x_{\max} representam o valor mínimo e máximo da série histórica, respectivamente, e x é o valor original da variável. O mesmo procedimento foi adotado para os dados de vazão de referência. Assim, seguindo a equação (3.1), se quisermos que um dado normalizado se apresente com peso 0, devemos substituí-lo na série de dados original de acordo com a equação (3.2), procedimento adotado neste trabalho para preenchimento de falhas na série histórica de vazões, geradas, provavelmente, por defeitos nos equipamentos de medição.

Um dos objetivos específicos deste trabalho consiste em avaliar o desempenho da rede neural RBF para vazões extremas. Para definir o conceito de vazão extrema, utilizou-se os dados de vazão observada entre os anos de 2003 e 2005 para criar um histograma da vazão deste período (Fig. 3.4). Através dele, pode-se observar que 55% das vazões estão concentradas entre 0 e 100 m³s⁻¹, aproximadamente 35% estão entre 100 e 200 m³s⁻¹ e apenas 10% são acima de 200 m³s⁻¹. Assim, definiu-se que para este trabalho, as vazões extremas são aquelas medições com valores superiores 200 m³s⁻¹.

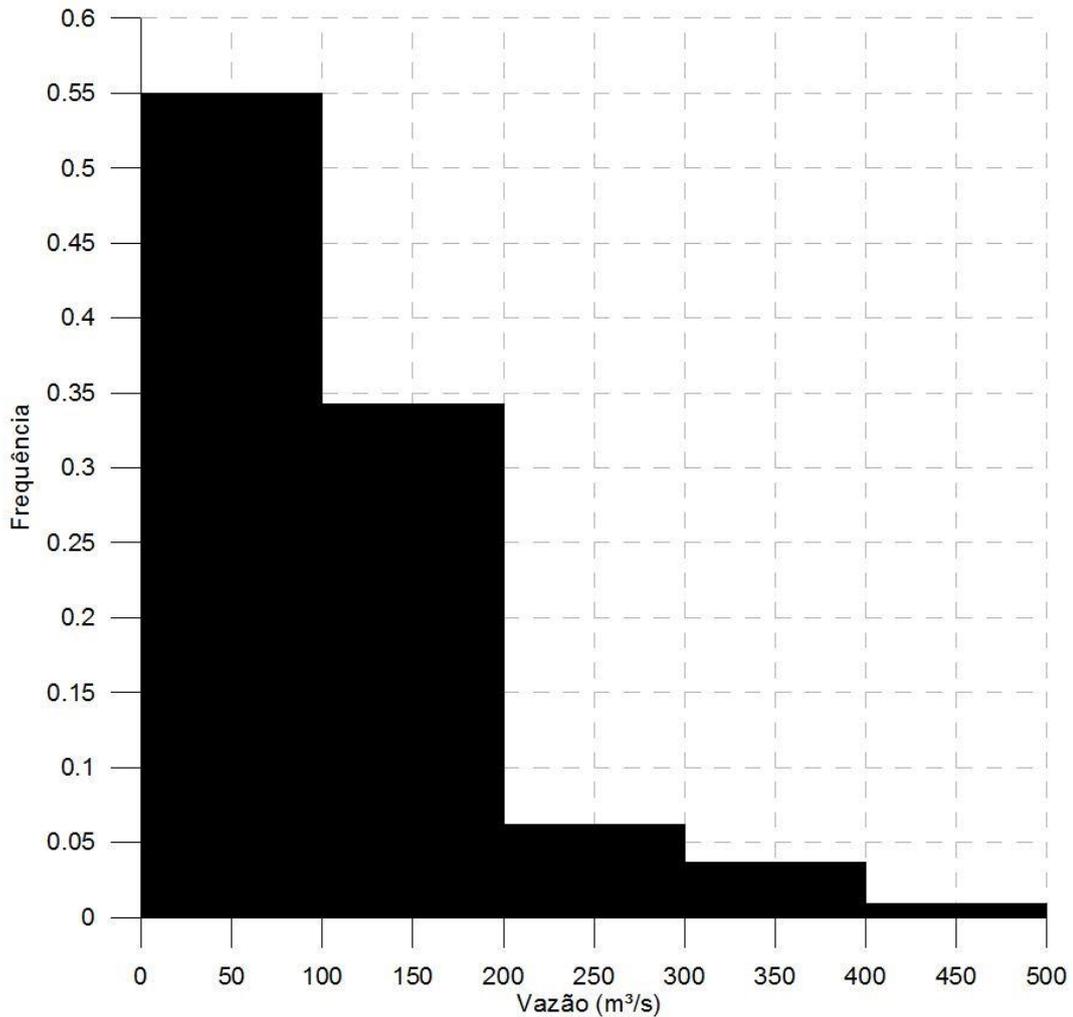


Figura 3.4 - Histograma de vazão

3.4 Treinamento e operação da RNA

Para cada uma das configurações citadas na seção 3.3, foram testadas diversas subconfigurações, variando o número de dias anteriores dos quais seriam utilizadas as vazões, precipitações e número de neurônios na camada oculta. As identificações dos experimentos foram escolhidas de tal maneira que se mantivessem semelhantes as identificações estabelecidas no trabalho de CABRAL (2013), sendo assim nomeadas:

- Dados de vazão média: Considerando que o primeiro dia de previsão seja i , o dia em que a previsão é realizada é $i-1$, e uma nomenclatura Q_n representa a utilização das vazões $Q(i-1)$, $Q(i-2)$, ..., $Q(i-n)$.
- Dados de precipitação média: Segue a mesma metodologia da vazão, onde i é o primeiro dia de previsão P_i .

- Número de neurônios: Representado pela nomenclatura Nk , onde k indica a quantidade de neurônios na camada intermediária da rede neural.

A tabela 4.1 mostra um exemplo da nomenclatura utilizada nos experimentos.

Tabela 4.1: Nomenclatura dos experimentos

Dados de Entrada	Nomenclatura
Q (i-3), Q (i-2), Q (i-1)	Q3N10
Q (i-5), Q (i-4), Q (i-3), Q (i-2), Q (i-1)	Q5N25
P (i-1) Q (i-4), Q (i-3), Q (i-2), Q (i-1)	P1Q4N8

Os códigos computacionais para treinamento, validação e teste da RNA do tipo RBF utilizados neste trabalho foram elaborados na linguagem FORTRAN e, posteriormente, organizados em um arquivo executável, elaborado e disponibilizado pelo Prof. Dr. Ricardo Carvalho de Almeida. É importante lembrar que a segunda validação com os dados referentes aos anos de 2003, 2004 e 2005 foi feita separadamente, sendo a validação realizada durante o treinamento apenas uma base para a escolha da melhor configuração para cada caso.

O computador utilizado para realizar os experimentos possui a seguinte especificação: processador Intel Core i5-2500k 3.30 GHz, memória RAM instalada de 8 GB, sistema operacional de 64 bits (Windows 10) e HD Kingston SSD 240 GB. Em média, cada experimento da fase de treinamento levava em torno de 20 minutos para ser concluído. Para a fase de operação, a duração da execução de cada experimento era de 1 minuto aproximadamente.

O primeiro programa executa um arquivo contendo os dados de entrada, preparado em um formato previamente definido, separando os dados em conjuntos de treinamento, teste e validação. Os percentuais de separação dos conjuntos foram arbitrados em 75%, 15% e 10%, respectivamente. Depois, os pares entrada/saída são embaralhados aleatoriamente através de um algoritmo de *shuffle*. O programa consiste em uma rede RBF realizando um treinamento em duas fases, como descrito na seção 2.2.8. Arbitrou-se um valor de 8000 e 15000 épocas para a primeira fase e segunda fase do treinamento, respectivamente. O parâmetro referente a taxa de aprendizagem da etapa de clusterização foi arbitrado em 0.010, sendo que quando este parâmetro estava com um valor maior, averiguou-se que os clusters se dirigiam para um ponto de estagnação, onde com o passar as épocas de treinamento eles não se deslocavam mais. Quando os clusters deslocavam-se, em relação a época anterior, menos que 10^{-8} , era a indicação

de que o ponto ótimo da etapa de clusterização havia sido encontrado. As funções de ativação gaussiana e linear foram selecionadas para a camada oculta e de saída, respectivamente.

O programa simula 10 iterações de validação cruzada e em cada iteração modificam-se os conjuntos de treinamento, teste e validação, dentro de um mesmo conjunto de dados. Desta maneira, a rede apresentará uma maior representatividade no treinamento dos dados. Para cada iteração é gerado um conjunto de resultados estatísticos, descritos seção 3.5. Um arquivo é criado contendo os dados estatísticos de cada validação e uma média simples para todas as validações, avaliando a qualidade de previsão da rede. Este procedimento tem como finalidade minimizar eventuais valores extremos das medidas escalares estatísticas produzidos por uma validação qualquer. No trabalho de CABRAL (2013), foi utilizado o melhor valor obtido de uma validação como resultado final para avaliação da configuração, ao invés de uma média de todas as iterações. Por fim, um arquivo contendo as posições otimizadas dos *clusters* e os pesos das sinapses relativas as camadas oculta e de saída é gerado para cada configuração experimentada.

O segundo programa, designado para operar a rede neural com os dados entre 2003 e 2005, recebe um arquivo com os dados de entrada referente a melhor configuração encontrada na fase de treinamento, junto de um arquivo que contém as posições otimizadas dos *clusters* e os pesos das sinapses. Análogo ao primeiro programa, também é criado um arquivo contendo os resultados estatísticos com a finalidade de avaliar a qualidade de previsão da rede.

O período de operação possui uma falha de 30 dias na série de vazões, correspondente ao mês de abril de 2005, preenchida de acordo com a equação 3.2 para treinamento e operação da rede. Esse período de dados foi excluído do trabalho de CABRAL (2013) para apresentação gráfica e cálculo dos coeficientes de eficiência por denegrir consideravelmente os resultados, levando até a previsões negativas. Com o intuito de mostrar a qualidade de previsão da rede RBF neste trabalho, este período de operação será considerado na apresentação gráfica e no cálculo dos coeficientes estatísticos.

A análise de vazões extremas é realizada utilizando os resultados fornecidos pela fase de operação da rede RBF, mediante uma filtragem dos resultados que não se adequavam ao conceito descrito previamente na seção 3.3. Por fim, as equações descritas na seção 3.5 foram inseridas no Software Excel para obter os índices estatísticos.

Para encontrar a melhor topologia para cada horizonte de previsão, foram realizados experimentos com uma variação de 5 até 25 neurônios na camada oculta. O número de dias anteriores dos quais seriam utilizadas as vazões foram arbitrados também, utilizando dados de

vazão de entrada entre Q1 e Q9. Também, foram escolhidos dados de precipitação variando de P1 até P7. O coeficiente de Nash-Sutcliffe foi utilizado para definir qual das configurações apresentou o melhor resultado e, em caso de empate entre duas configurações com relação ao coeficiente de Nash-Sutcliffe, foi utilizado a raiz do erro médio quadrático (RMS) como critério de desempate.

3.5 Análise estatística dos resultados

Os resultados são submetidos a certos índices estatísticos característicos, visando classificar os experimentos. Os índices utilizados neste trabalho são: desvio de vazões, raiz do erro médio quadrático e coeficiente de Nash-Sutcliffe. Nas formulações seguintes, as variáveis $Q_{i,obs}$, $Q_{i,calc}$ e n significam, respectivamente, vazão observada, vazão calculada e número de dados.

- Raiz do Erro Médio Quadrático (RMS): é inversamente proporcional a previsão, ou seja, quanto maior o valor de RMS, menor a acurácia dos resultados em relação a realidade. Ter um erro quadrático médio de zero é o ideal, mas na maioria das situações nunca é possível. Além disso, um valor de RMS igual a zero significa que o estimador prevê observações com acurácia perfeita.

$$RMS = \sqrt{\frac{\sum_{i=1}^n (Q_{i,obs} - Q_{i,calc})^2}{n}} \quad (3.3)$$

- Coeficiente de Nash-Sutcliffe (NASH): Um dos mais importantes critérios estatísticos para avaliar o ajuste de modelos hidrológicos é o coeficiente de Nash-Sutcliffe. O coeficiente pode variar entre $[-\infty, 1]$, sendo o valor 1 indicativo de um perfeito ajuste. Quando o valor do coeficiente resultar maior que 0,75, o desempenho do modelo é considerado bom. Para valores entre 0,36 e 0,75, o desempenho é considerado aceitável, enquanto valores inferiores a 0,36 fazem com que o modelo em questão seja julgado como inaceitável (ASCE, 1993).

$$NASH = 1 - \frac{\sum_{i=1}^n (Q_{calc,i} - Q_{obs,i})^2}{\sum_{i=1}^n (Q_{obs,i} - \overline{Q_{calc,i}})^2} \quad (3.4)$$

- Média dos Valores Absolutos dos Desvios (MAD): Dimensiona o desvio (m³/s) das previsões em relação ao valor real; Localidades com vazões maiores tendem a ter valores de MAD também mais elevados.

$$MAD = \frac{1}{n} \sum_{i=1}^n |Q_{obs,i} - Q_{calc,i}| \quad (3.5)$$

4 RESULTADOS E DISCUSSÕES

4.1 Análise global dos resultados

4.1.1 Treinamento

Foram realizados mais de 700 experimentos neste trabalho para as diferentes configurações, com variações nos dados de entrada e no número de neurônios na camada oculta. Todos os resultados destes treinamentos estão disponíveis no Apêndice A, nas tabelas A.1 a A.7, cada uma referente a um horizonte de previsão.

As melhores configurações de treinamento encontradas neste trabalho serão apresentadas em tabelas em conjunto com os resultados estatísticos das melhores configurações encontradas por CABRAL (2013). Para a rede RBF, será apresentado a média das 10 iterações, para o melhor experimento. Para a rede MLP, será apresentado o melhor valor encontrado pela autora, para a melhor configuração.

Além disso, será apresentado um gráfico, referente a cada horizonte de previsão, com os índices de Nash-Sutcliffe encontrados nas diferentes configurações durante o treinamento. Os experimentos de 1 até 25 pertencem a configuração que utiliza apenas dados de vazão pretérita, enquanto que os experimentos 26 até 100 pertencem a configuração que usa dados de vazão e precipitação pretéritos.

A tabela 4.1 contém todos os valores estatísticos para os índices de NASH e RMS para os dois trabalhos, referentes a todos os horizontes de previsão. Ressaltando também que índice MAD não foi calculado por CABRAL (2013) na fase de treinamento. As figuras 4.1 a 4.7, mostram o índice de Nash-Sutcliffe para todos os experimentos produzidos pela rede RBF nos diferentes horizontes de previsão.

Por último, adicionou-se apenas um gráfico que contempla o conjunto de erro de treinamento do experimento P5Q9N5, referente a previsão com horizonte de 1 dia. Como todos os gráficos apresentaram comportamento semelhante, decidiu-se apresentar apenas um exemplo. Todos os gráficos do conjunto de erro de treinamento relativos as melhores

configurações de treinamento apresentadas abaixo encontram-se no Apêndice B, nos gráficos B.1 a B.13.

Tabela 4.1 - Índices de qualidade obtidos durante o treinamento, com todos os horizontes de previsão

Previsão com horizonte de 1 dia	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N20	P5Q9N5	Q8N2	P1Q4N3
	NASH	0.95	0.95	0,99	0.99
	RMS (m ³ /s)	23.26	24.84	12.62	11.27
	MAD (m ³ /s)	6.19	7.37	-	-
Previsão com horizonte de 2 dias	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N25	P5Q7N10	Q5N2	P1Q6N2
	NASH	0.91	0.92	0.97	0.98
	RMS (m ³ /s)	34.50	31.40	17.98	24.16
	MAD (m ³ /s)	12.61	12.09	-	-
Previsão com horizonte de 3 dias	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N5	P5Q7N20	Q1N2	P1Q2N2
	NASH	0.85	0.90	0.90	0.91
	RMS (m ³ /s)	45.03	37.00	32.60	43.00
	MAD (m ³ /s)	20.09	18.30	-	-
Previsão com horizonte de 4 dias	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N20	P5Q9N20	Q2N2	P1Q4N2
	NASH	0.81	0.88	0.92	0.77
	RMS (m ³ /s)	50.75	39.96	28.36	119.96
	MAD (m ³ /s)	26.38	21.96	-	-
Previsão com horizonte de 5 dias	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N15	P5Q7N20	Q6N2	P1Q1N3
	NASH	0.76	0.84	0.69	0.74
	RMS (m ³ /s)	57.84	46.64	76.40	58.36
	MAD (m ³ /s)	32.08	26.79	-	-
Previsão com horizonte de 6 dias	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N10	P5Q7N5	Q3N2	P1Q5N2
	NASH	0.68	0.79	0.68	0.66
	RMS (m ³ /s)	66.46	54.12	66.09	54.46

	MAD (m ³ /s)	37.15	32.09	-	-
Previsão com horizonte de 7 dias	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N10	P5Q9N10	Q4N3	P1Q3N4
	NASH	0.63	0.73	0.55	0.75
	RMS (m ³ /s)	70.78	60.93	72.95	51.26
	MAD (m ³ /s)	40.69	36.16	-	-

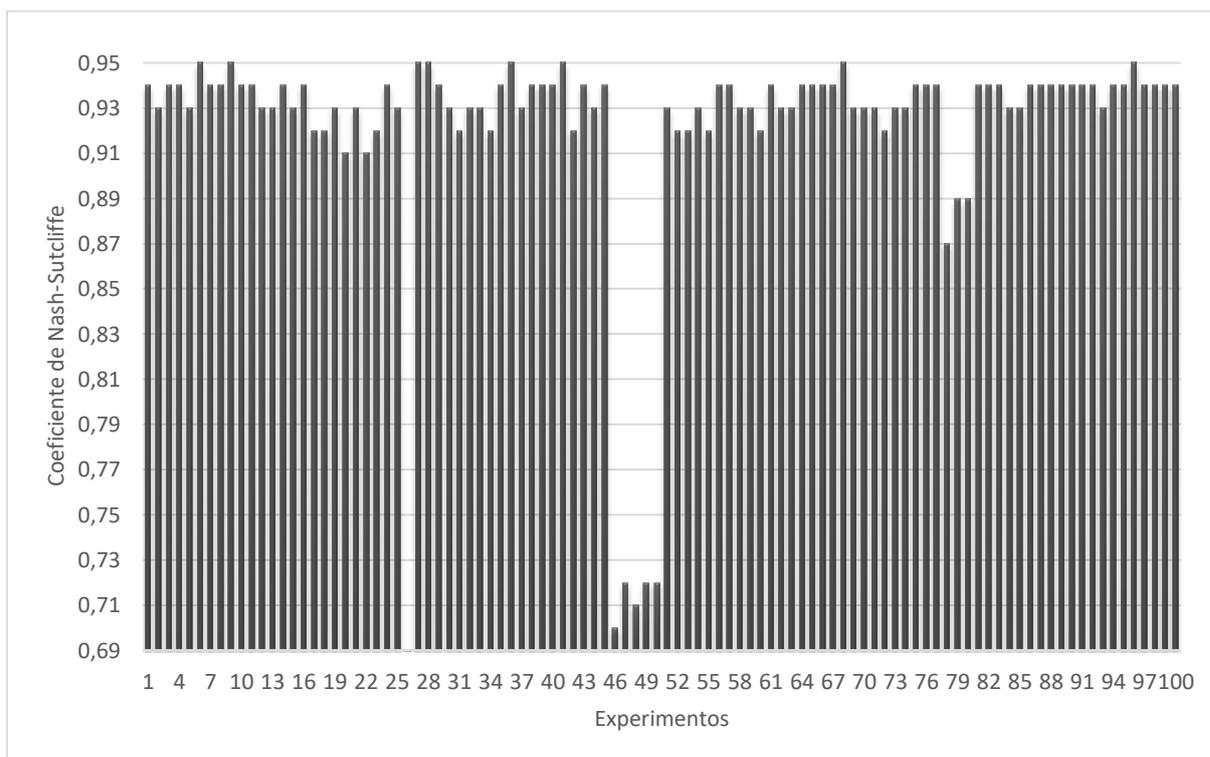


Figura 4.1 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de um dia.

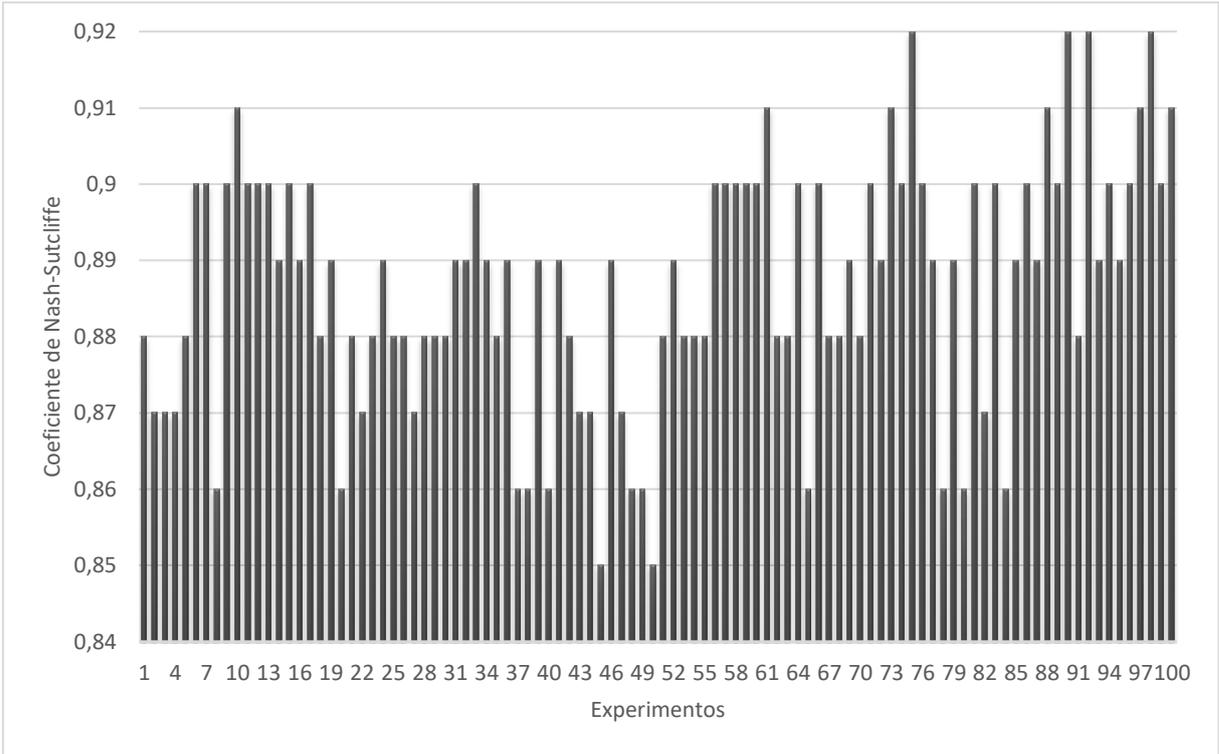


Figura 4.2 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de dois dias.

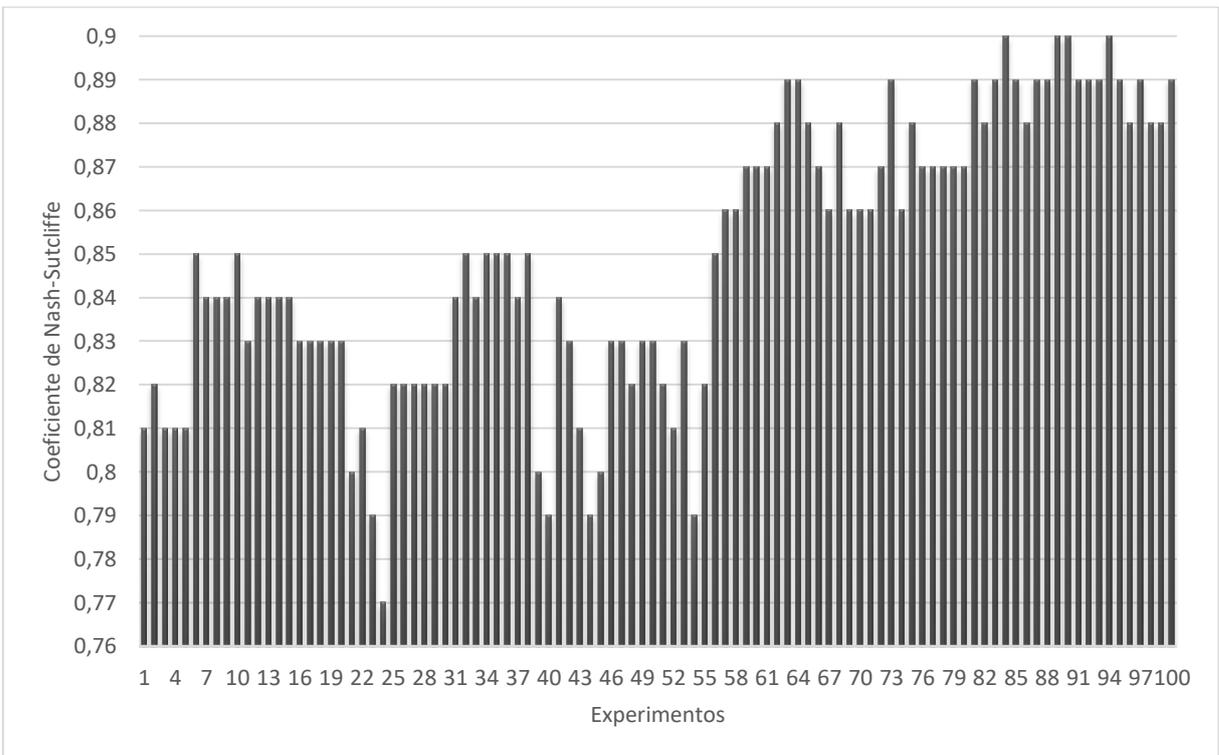


Figura 4.3 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de três dias.

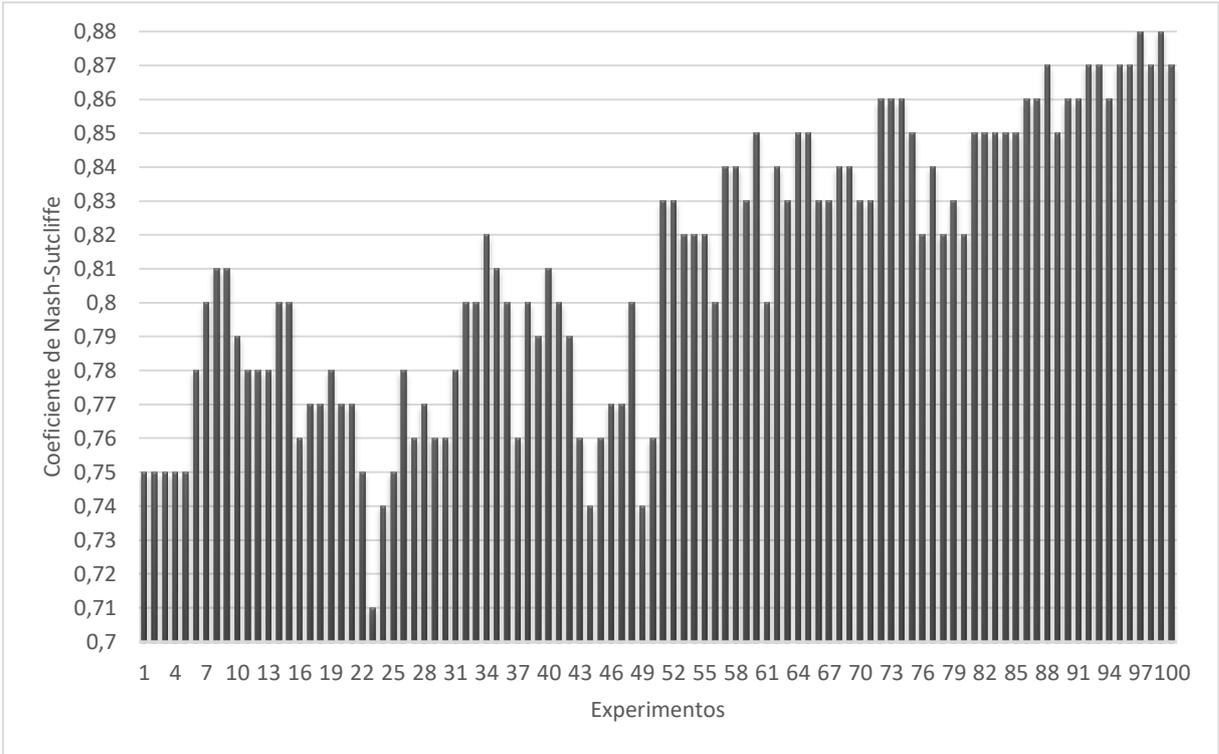


Figura 4.4 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de quatro dias.

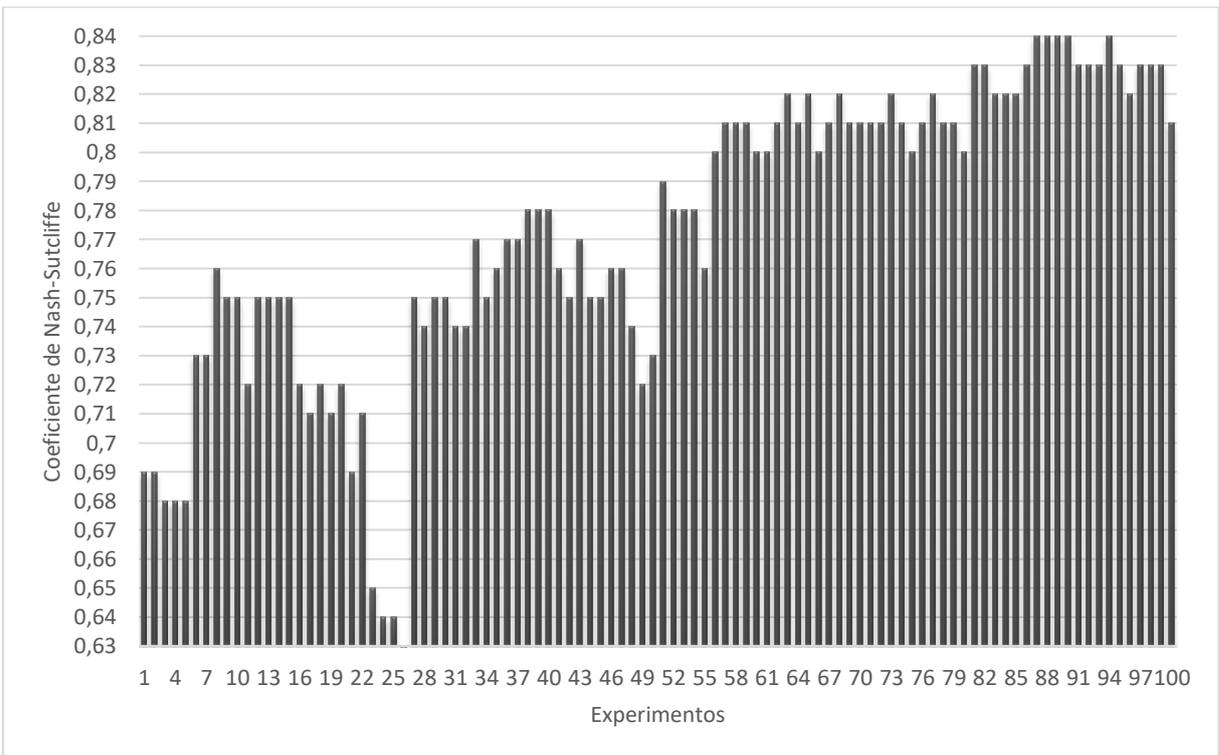


Figura 4.5 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de cinco dias.

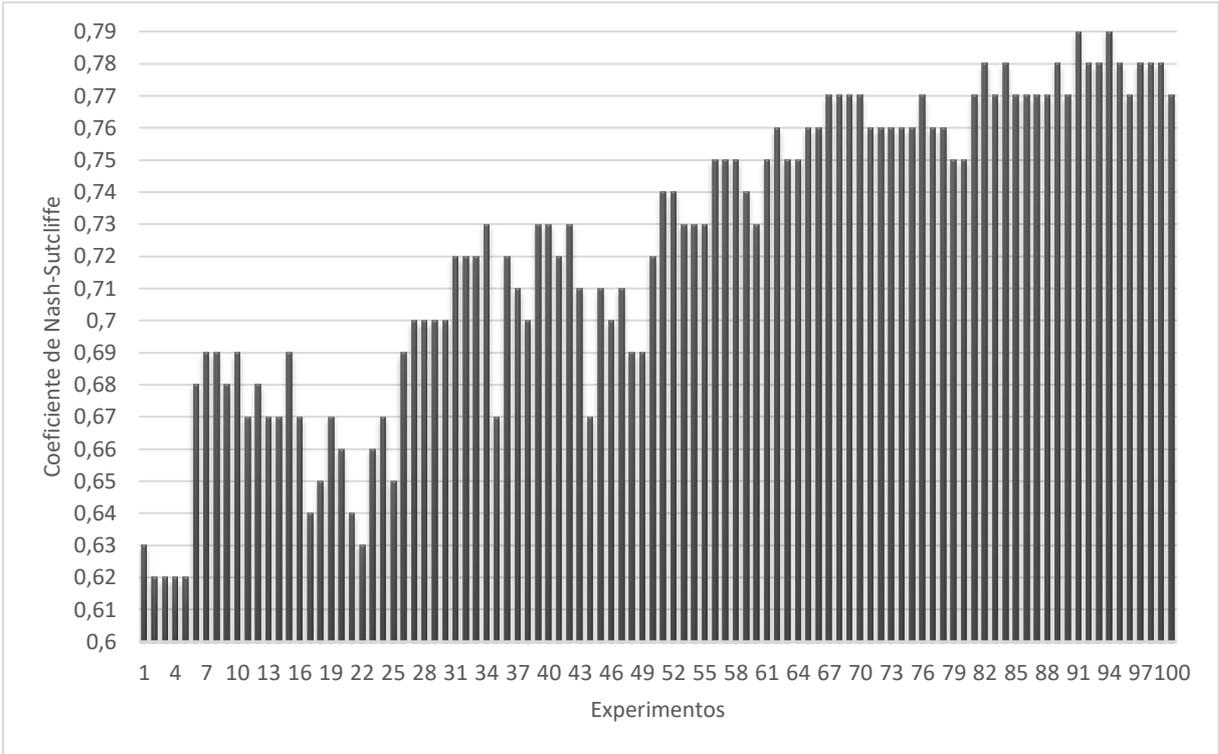


Figura 4.6 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de seis dias.

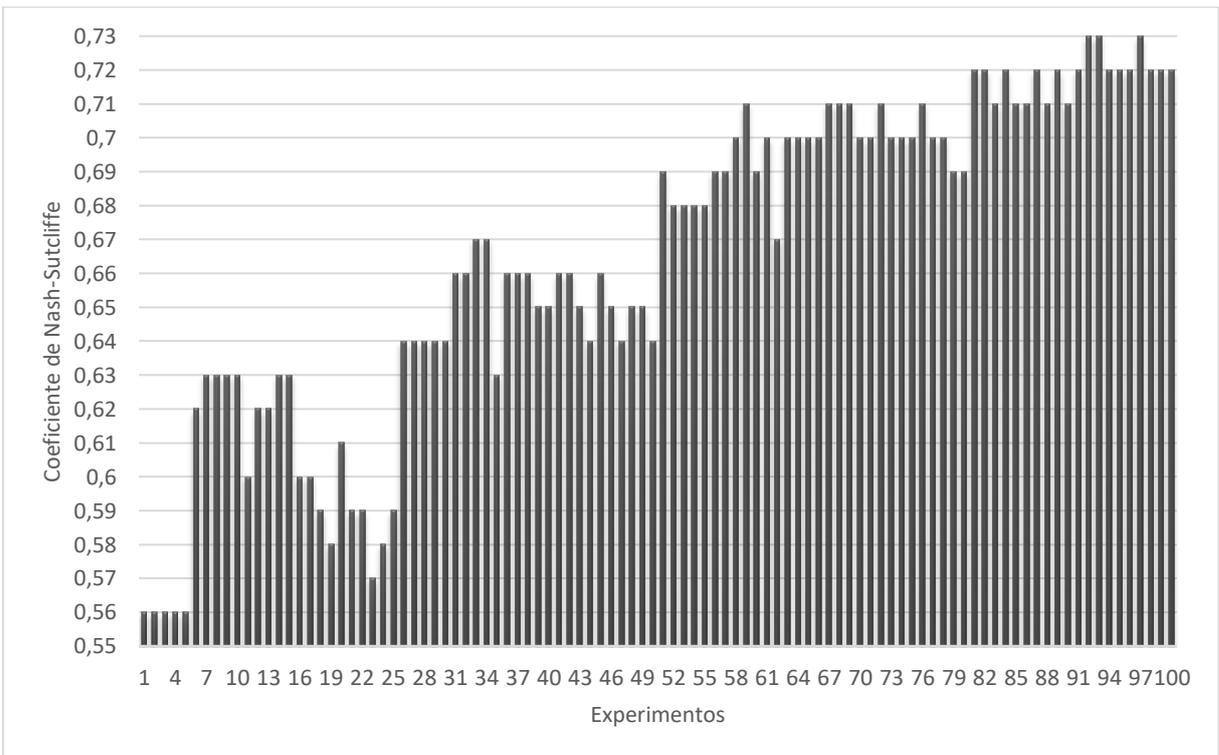


Figura 4.7 - Coeficiente de Nash-Sutcliffe para todos os experimentos, com horizonte de sete dias.

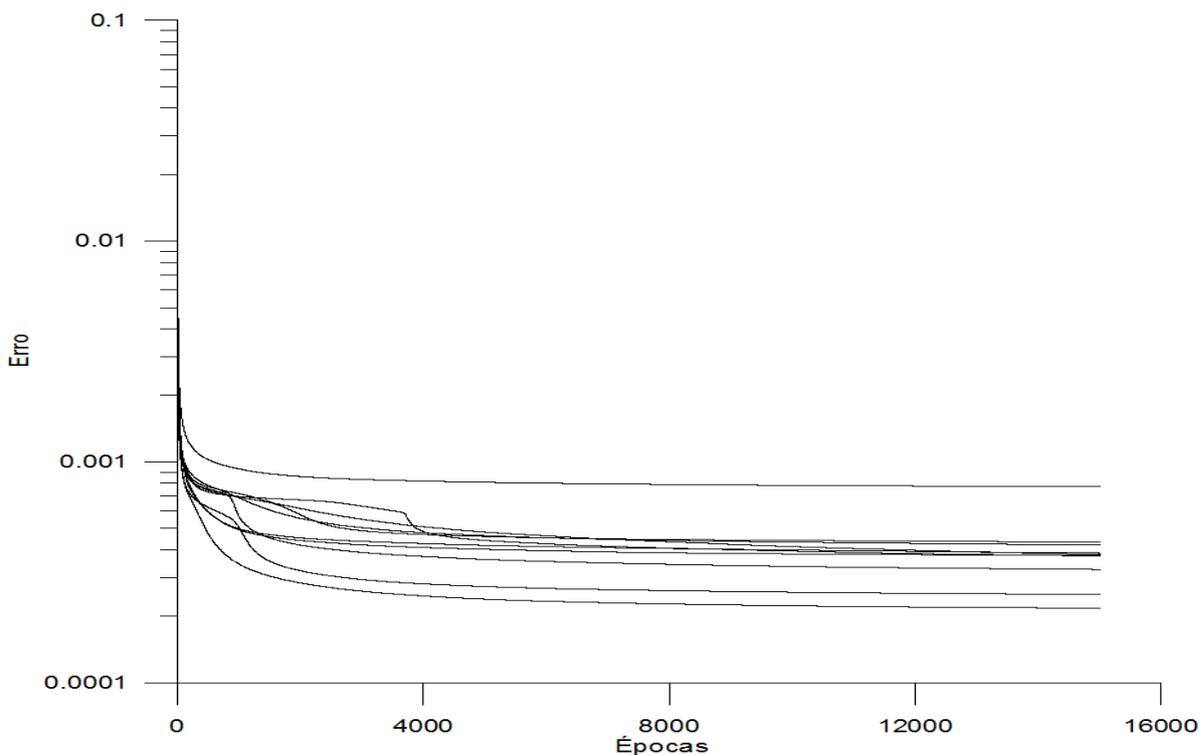


Figura 4.8 - Erro do conjunto de treinamento do experimento P5Q9N5 para previsão com horizonte de 1 dia

Observando a Tab. 4.1, pode-se notar que a rede MLP apresentou resultados minimamente melhores que a rede RBF, em relação ao coeficiente de Nash-Sutcliffe com o horizonte de previsão de um dia. Está pequena margem entre os coeficientes das redes se mantém até as previsões com horizonte de três dias, onde já é possível perceber que os desempenhos das redes parecem se igualar. Para os horizontes seguintes, com exceção do último horizonte de previsão, o coeficiente de Nash-Sutcliffe para a rede RBF mostra-se um pouco maior do que para a rede MLP.

Quanto aos resultados da figura 4.1, um dos experimentos apresentou o coeficiente de Nash-Sutcliffe negativo, não sendo contemplado no gráfico. Na figura 4.5 também pode-se observar o mesmo evento. Ainda se tratando dos resultados da figura referente ao primeiro horizonte de previsão, pode-se constatar que entre os experimentos 46 e 50, referentes a configuração P1Q9, apresentaram resultados aproximadamente 75% piores em relação à média de valores encontrados para NASH durante toda a faixa de valores da etapa de treinamento.

Analisando todos os resultados das figuras apresentadas nesta seção, pode-se observar que existe uma tendência onde, conforme há o avanço no horizonte de previsão, a inserção de mais dados de precipitação (P1 até P7) parece influenciar positivamente no resultado final do coeficiente de Nash-Sutcliffe.

De acordo com a figura 4.8, é possível inferir que o treinamento das dez iterações convergiu para um mesmo mínimo global. Após 4000 épocas de treinamento o erro permanece praticamente o mesmo, caindo lentamente ao decorrer das épocas restantes, sugerindo que um ponto ótimo de posicionamento dos clusters tenha sido encontrado.

4.1.2 Operação

Foram realizados 14 experimentos nesta etapa do trabalho, sendo dois experimentos para cada horizonte de previsão, com as melhores configurações encontradas na fase de treinamento. A tabela 4.8 apresenta todos os resultados estatísticos encontrados pela rede RBF em conjunto com todas as melhores configurações encontradas por CABRAL (2013) na fase de operação. O índice RMS não foi calculado para a fase de operação no trabalho da autora, sendo contemplado nestas tabelas. Além disso, serão apresentados uma série de gráficos, para cada horizonte de previsão, contendo um diagrama de dispersão para cada configuração e uma sobreposição entre as curvas dos hidrogramas observadas e previstas de cada experimento.

Tabela 4.2 - Índices de qualidade obtidos durante a operação, para todos os horizontes de previsão.

Previsão com horizonte de 1 dia	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N20	P5Q9N5	Q8N2	P1Q4N3
	NASH	0.99	0.99	0.98	0.98
	RMS (m ³ /s)	7.81	7.56	-	-
	MAD (m ³ /s)	4.33	4.67	6.89	6.41
Previsão com horizonte de 2 dias	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N25	P5Q7N10	Q5N2	P1Q6N2
	NASH	0.96	0.97	0.94	0.94
	RMS (m ³ /s)	15.86	14.03	-	-
	MAD (m ³ /s)	9.64	8.86	13.68	12.94
Previsão com horizonte de 3 dias	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N5	P5Q7N20	Q1N2	P1Q2N2
	NASH	0.90	0.93	0.85	0.87
	RMS (m ³ /s)	24.66	20.43	-	-
	MAD (m ³ /s)	16.33	13.58	21.83	18.97

Previsão com horizonte de 4 dias	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N20	P5Q9N20	Q2N2	P1Q4N2
	NASH	0.84	0.88	0.78	0.80
	RMS (m ³ /s)	31.77	26.79	-	-
	MAD (m ³ /s)	22.42	18.73	27.40	24.80
Previsão com horizonte de 5 dias	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N15	P5Q7N20	Q6N2	P1Q1N3
	NASH	0.75	0.82	0.71	0.73
	RMS (m ³ /s)	39.25	32.95	-	-
	MAD (m ³ /s)	29.05	23.78	32.65	29.79
Previsão com horizonte de 6 dias	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N10	P5Q7N5	Q3N2	P1Q5N2
	NASH	0.67	0.75	0.64	0.65
	RMS (m ³ /s)	45.17	39.65	-	-
	MAD (m ³ /s)	34.32	29.73	38.12	33.92
Previsão com horizonte de 7 dias	Tipo de Rede	Rede RBF		Rede MLP	
	Configuração	Q3N10	P5Q9N10	Q4N3	P1Q3N4
	NASH	0.59	0.68	0.53	0.57
	RMS (m ³ /s)	50.58	44.32	-	-
	MAD (m ³ /s)	38.43	33.81	41.35	38.81

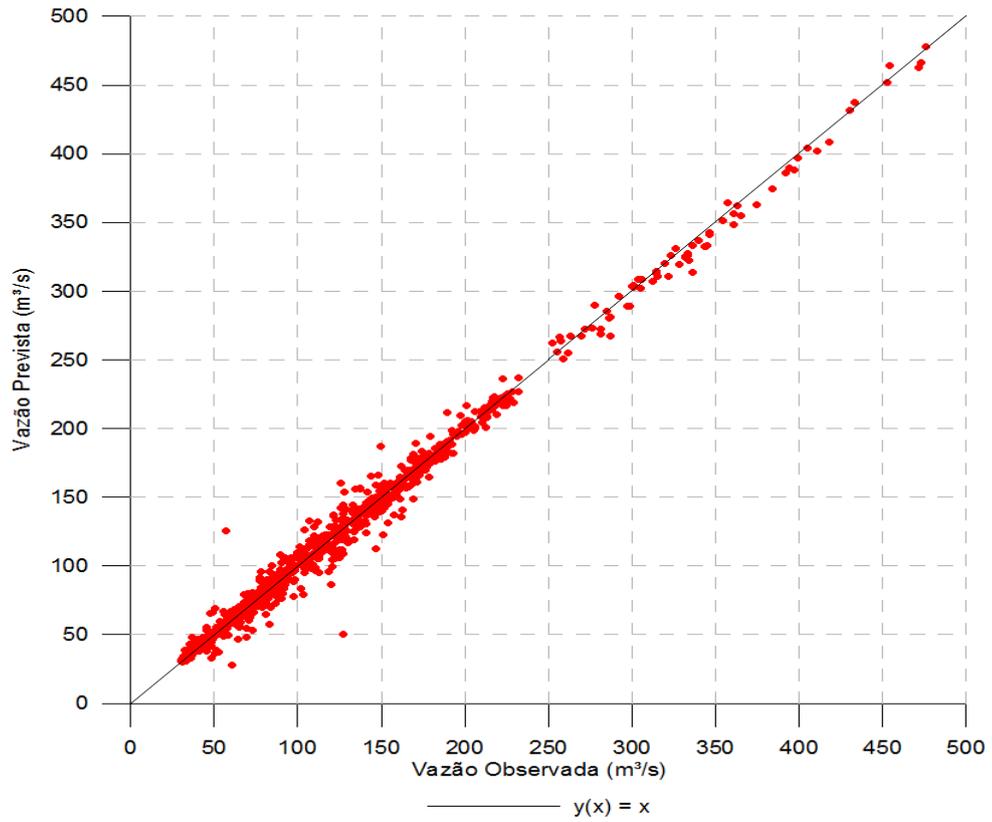


Figura 4.9 - Diagrama de dispersão com horizonte de 1 dia, experimento P5Q9N5

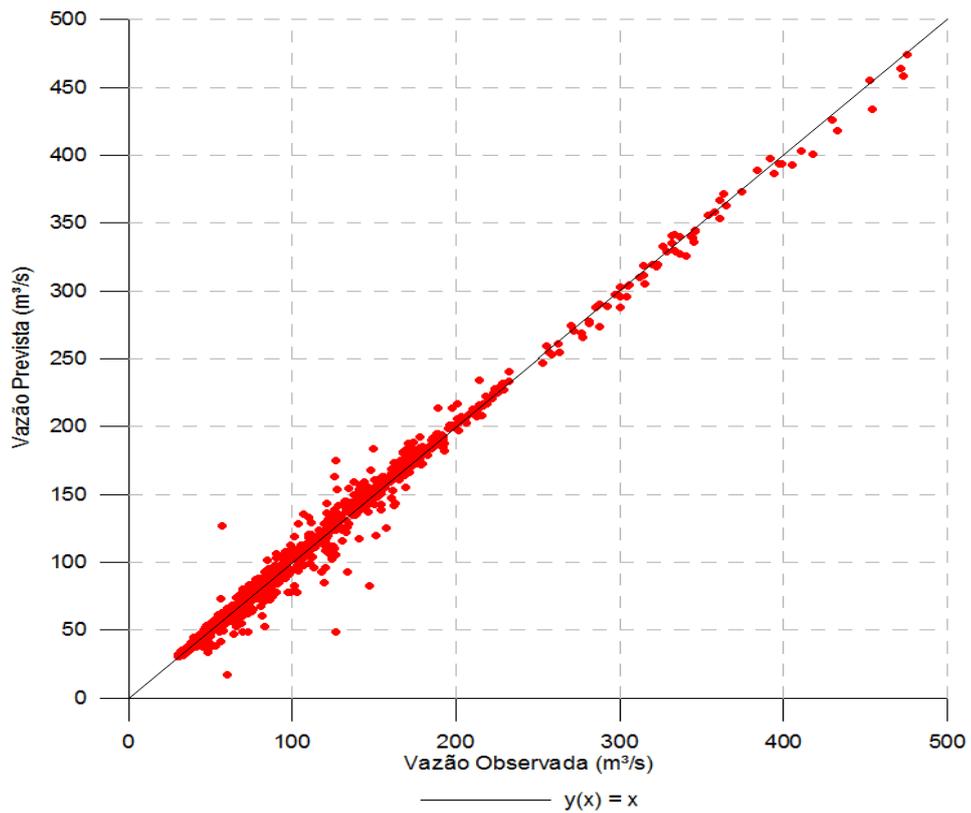


Figura 4.10 - Diagrama de dispersão com horizonte de 1 dia, experimento Q3N20

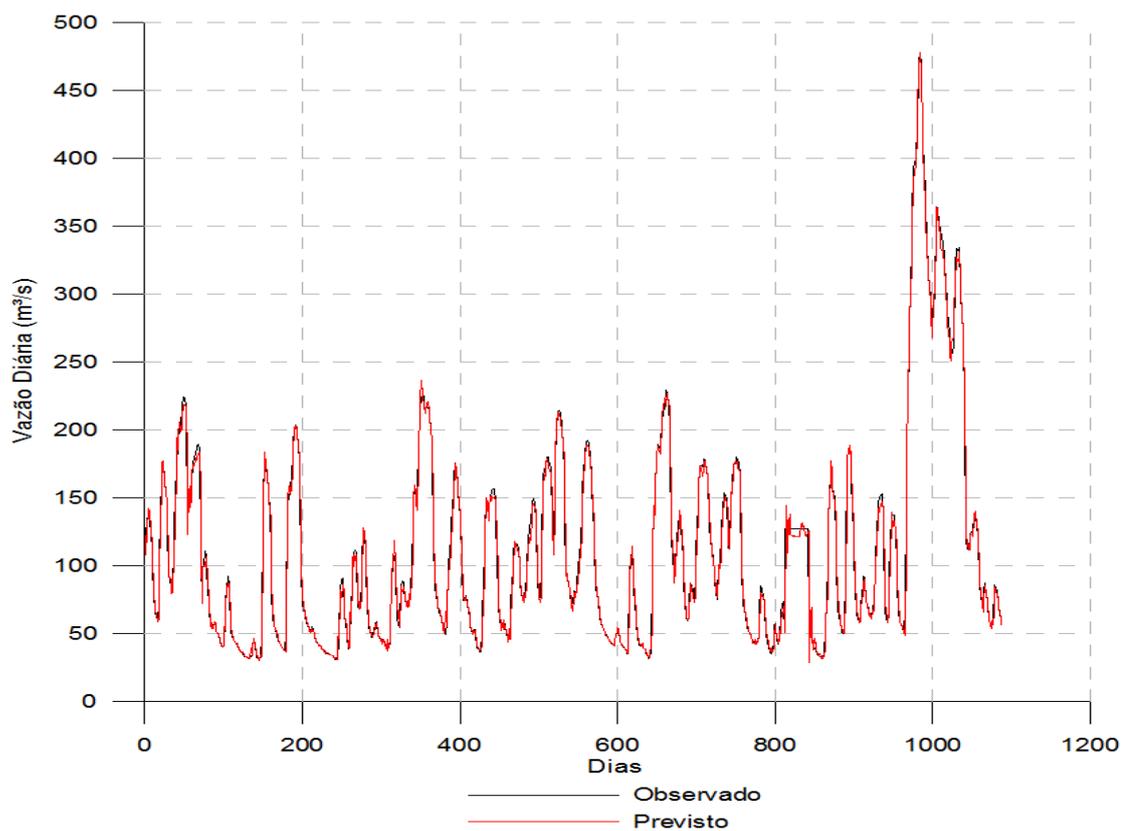


Figura 4.11 - Vazões observada e prevista pelo modelo, no experimento P5Q9N5, com horizonte de 1 dia

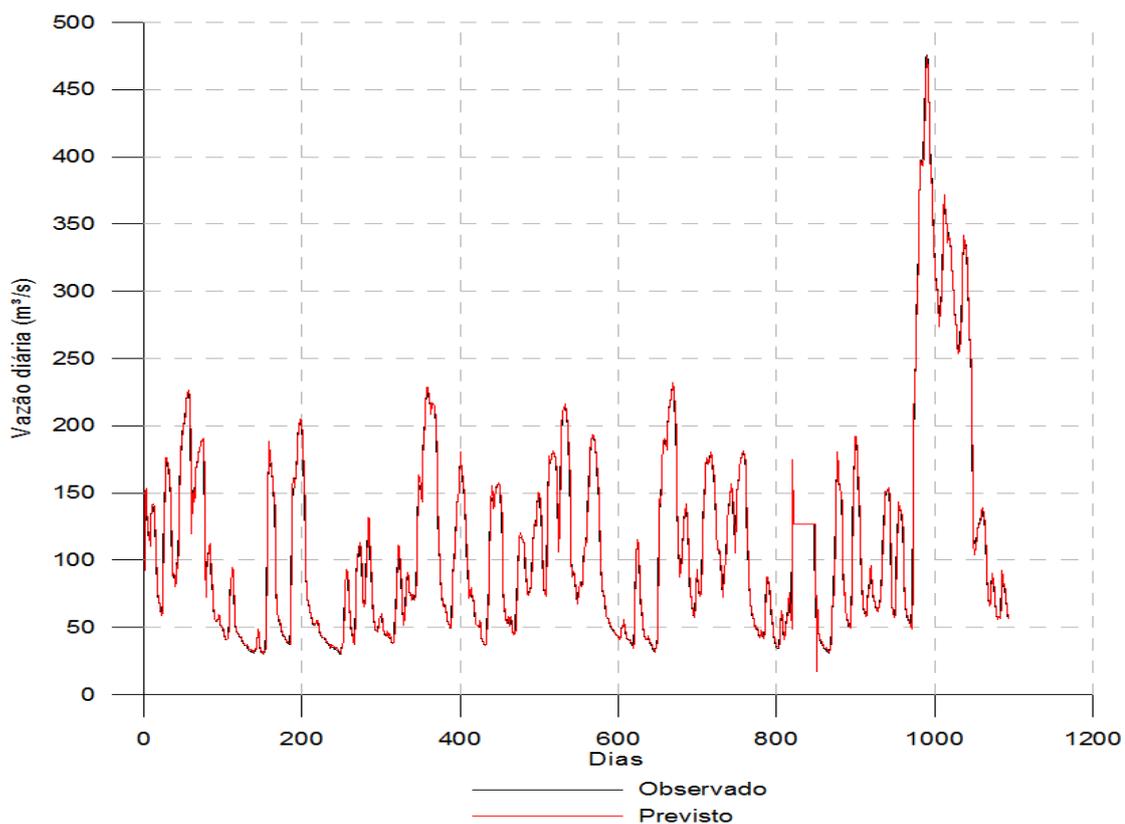


Figura 4.12 - Vazões observada e prevista pelo modelo, no experimento Q3N20, com horizonte de 1 dia

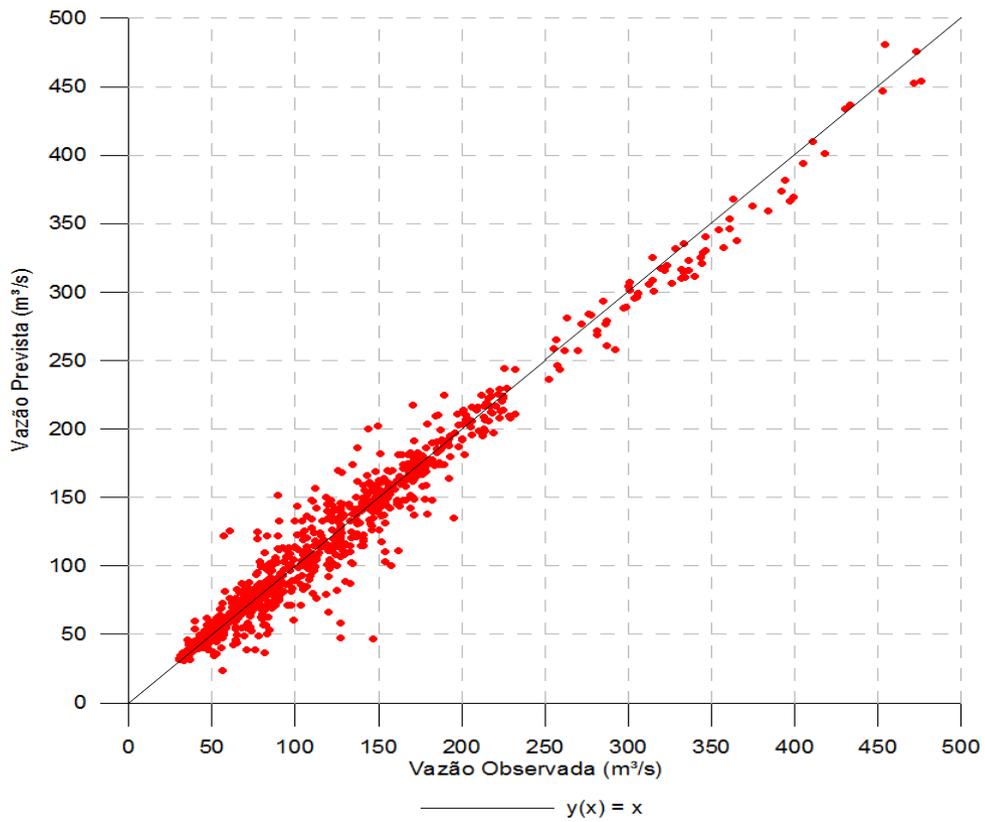


Figura 4.13 - Diagrama de dispersão com horizonte de 2 dias, experimento P5Q7N10

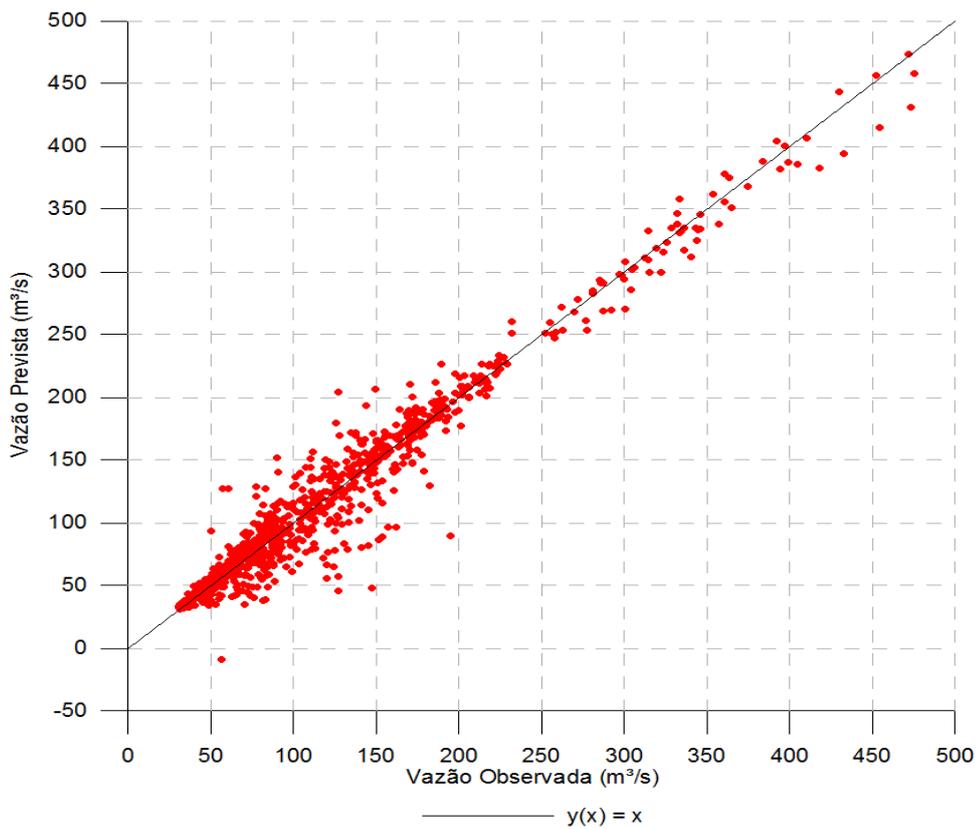


Figura 4.14 - Diagrama de dispersão com horizonte de 2 dias, experimento Q3N25

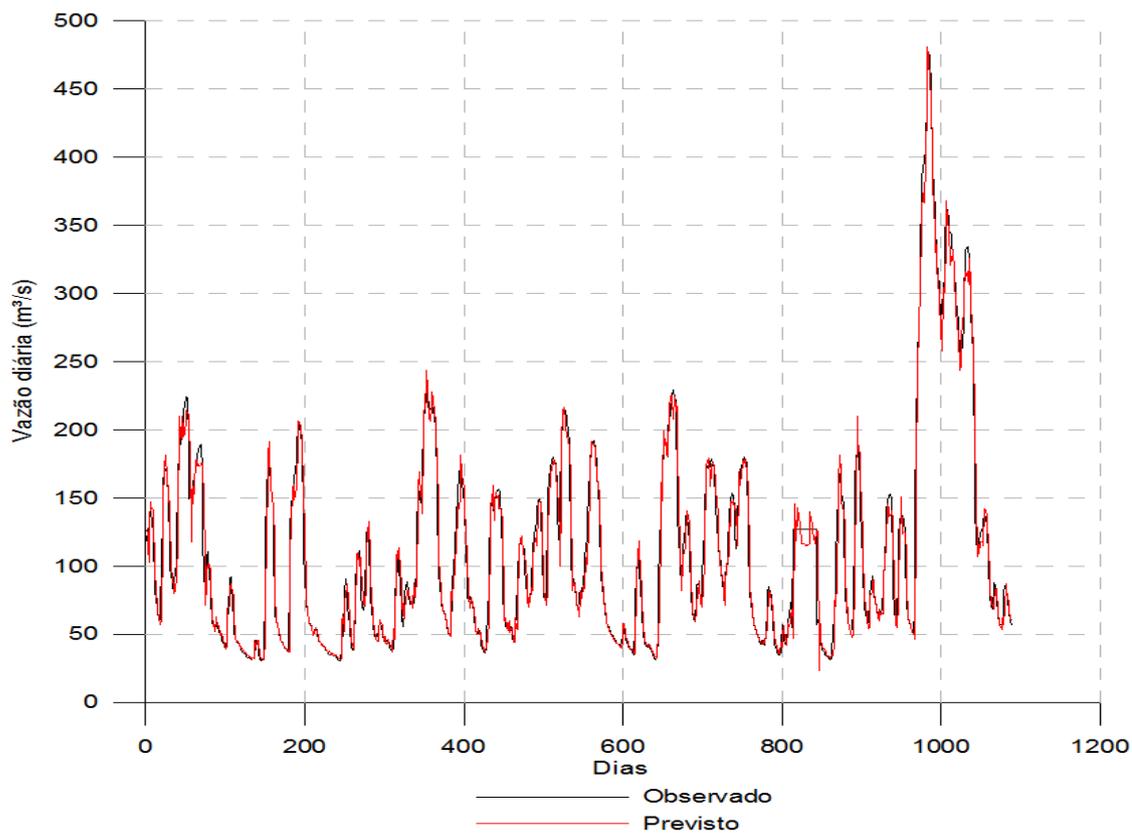


Figura 4.15 - Vazões observada e prevista pelo modelo, no experimento P5Q7N10, com horizonte de 2 dias

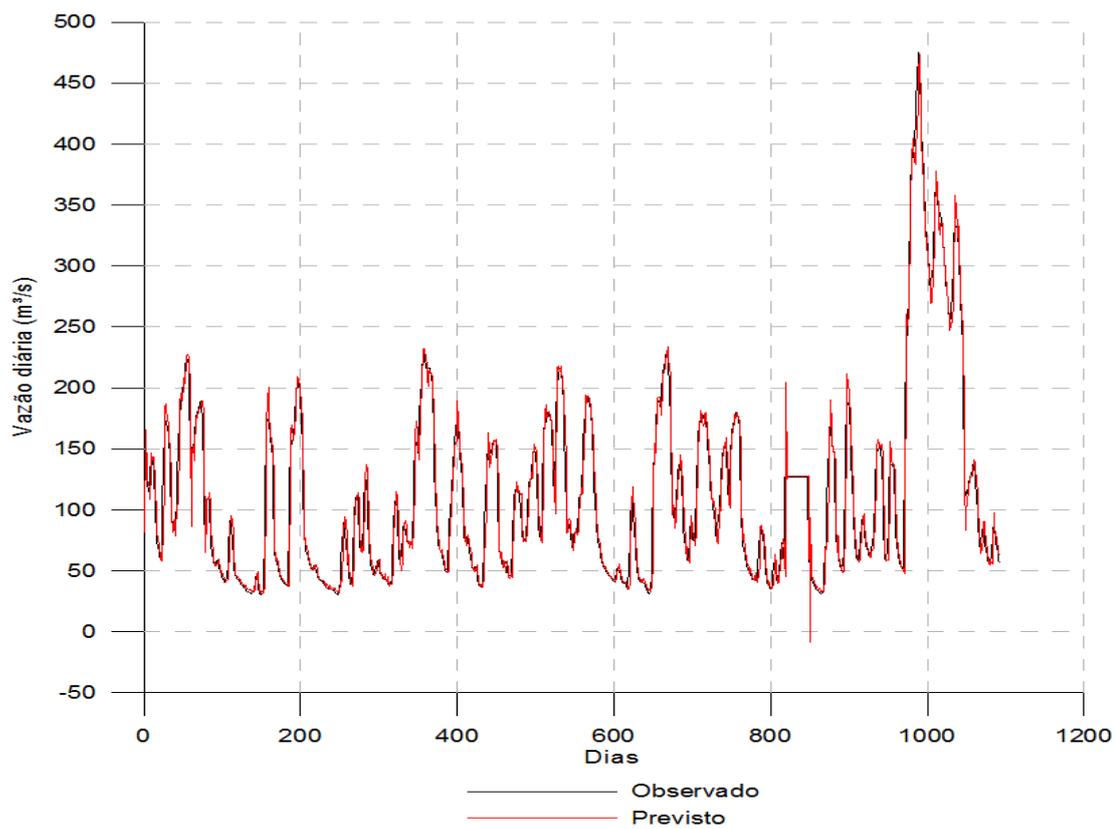


Figura 4.16 - Vazões observada e prevista pelo modelo, no experimento Q3N25, com horizonte de 2 dias

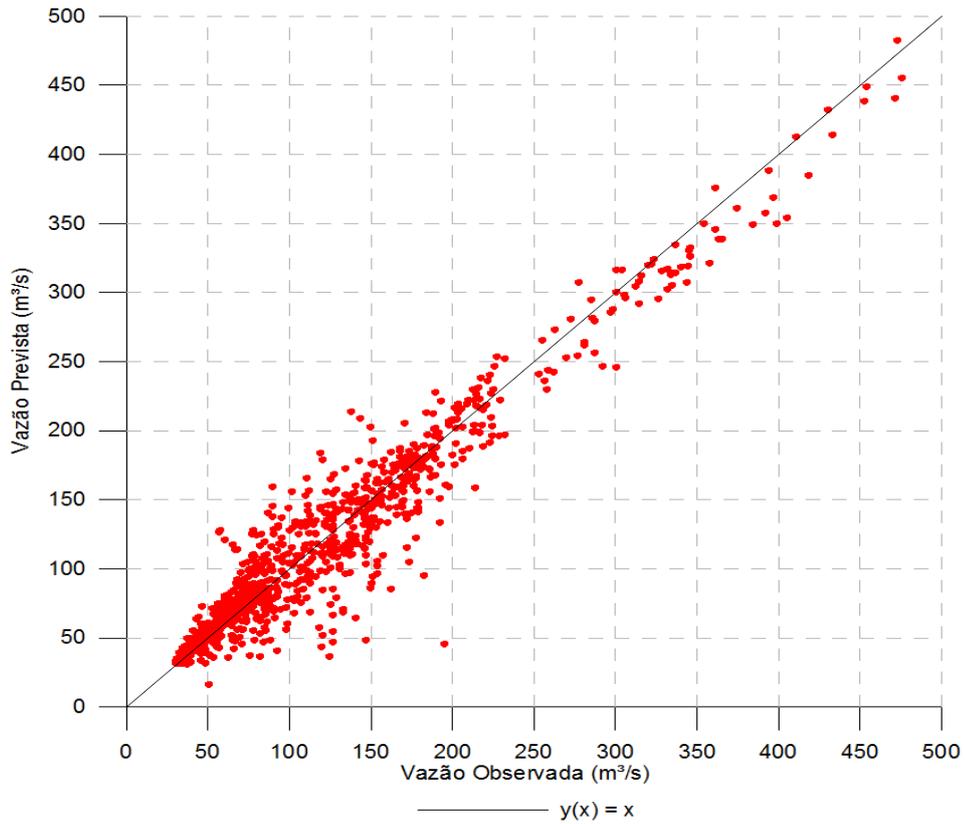


Figura 4.17 - Diagrama de dispersão com horizonte de 3 dias, experimento P5Q7N20

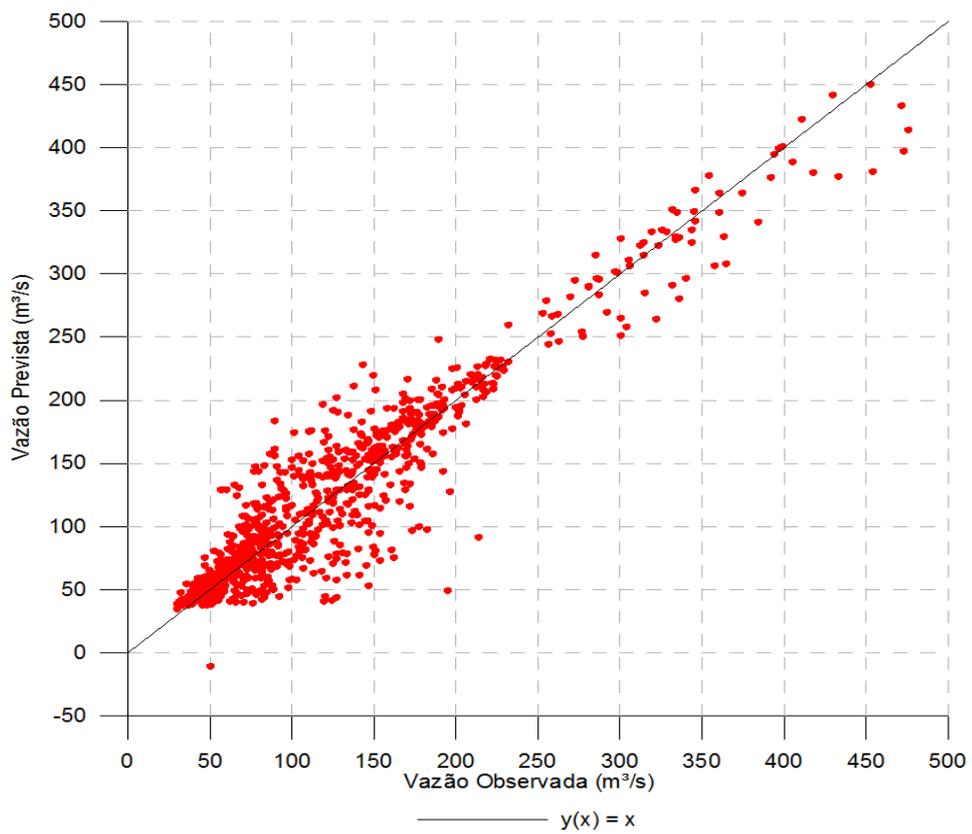


Figura 4.18 - Diagrama de dispersão com horizonte de 3 dias, experimento Q3N5

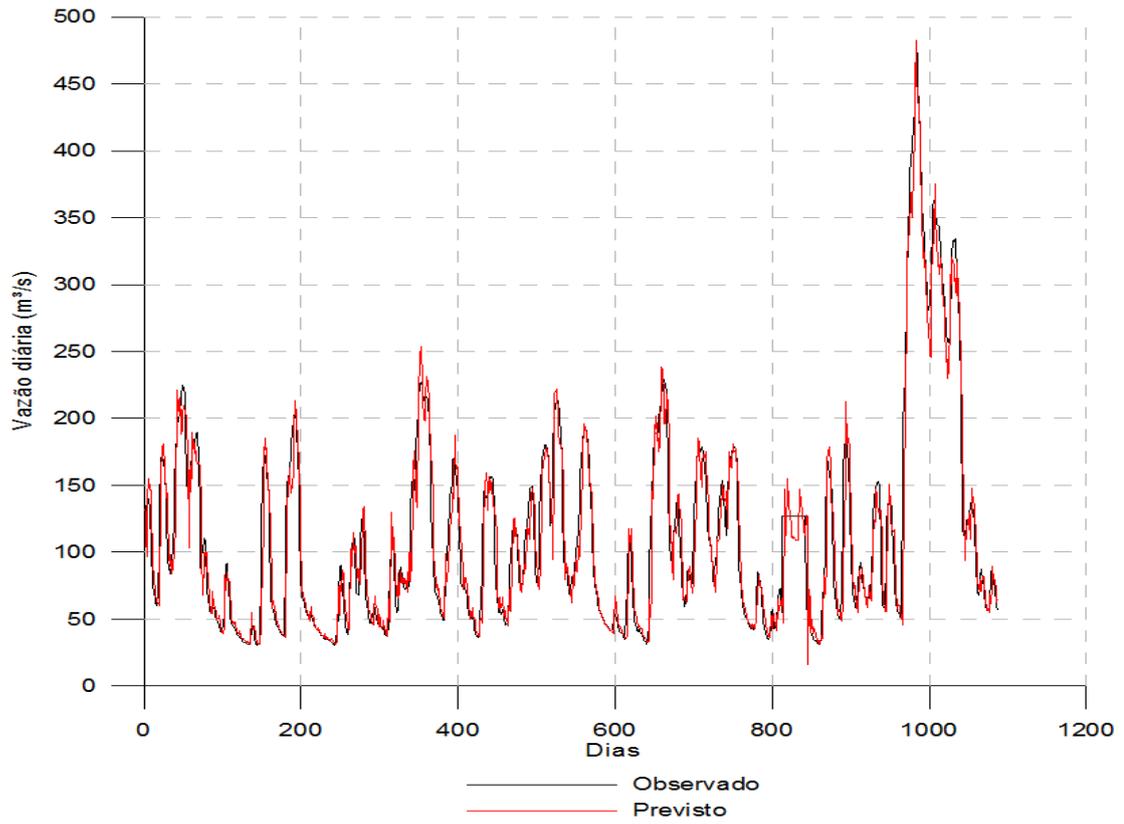


Figura 4.19 - Vazões observada e prevista pelo modelo, no experimento P5Q7N20, com horizonte de 3 dias

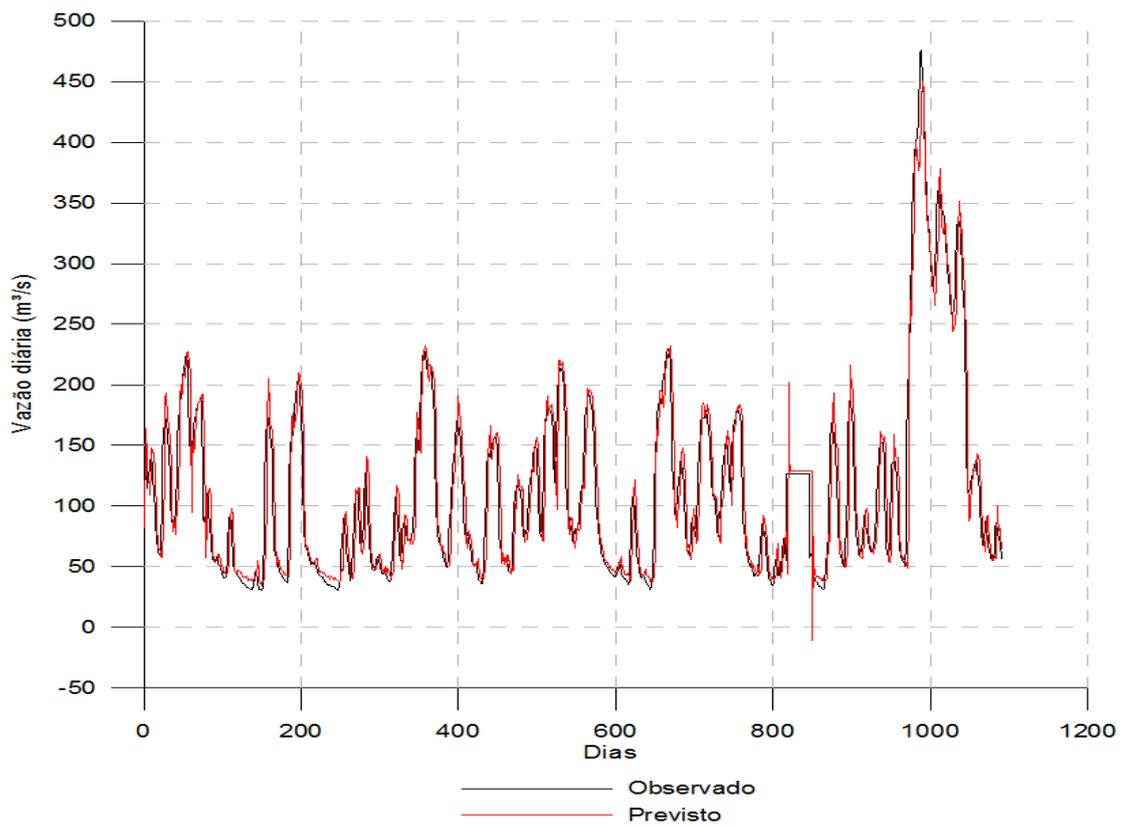


Figura 4.20 - Vazões observada e prevista pelo modelo, no experimento Q3N5, com horizonte de 3 dias

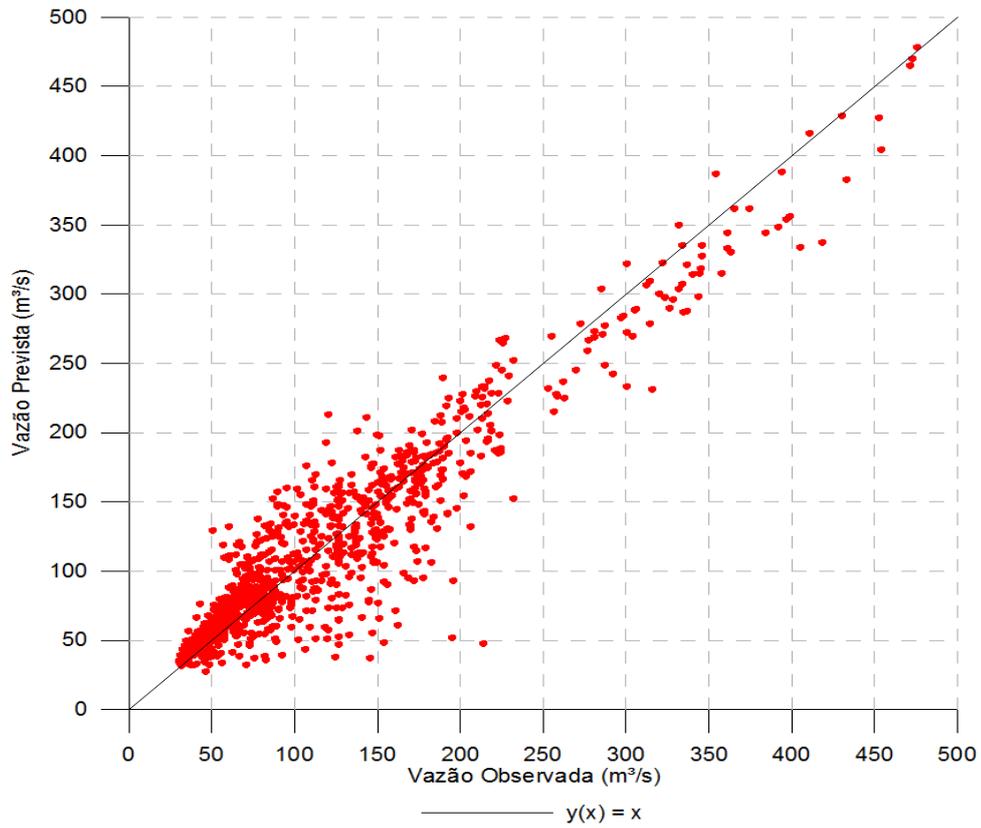


Figura 4.21 - Diagrama de dispersão com horizonte de 4 dias, experimento P5Q9N20

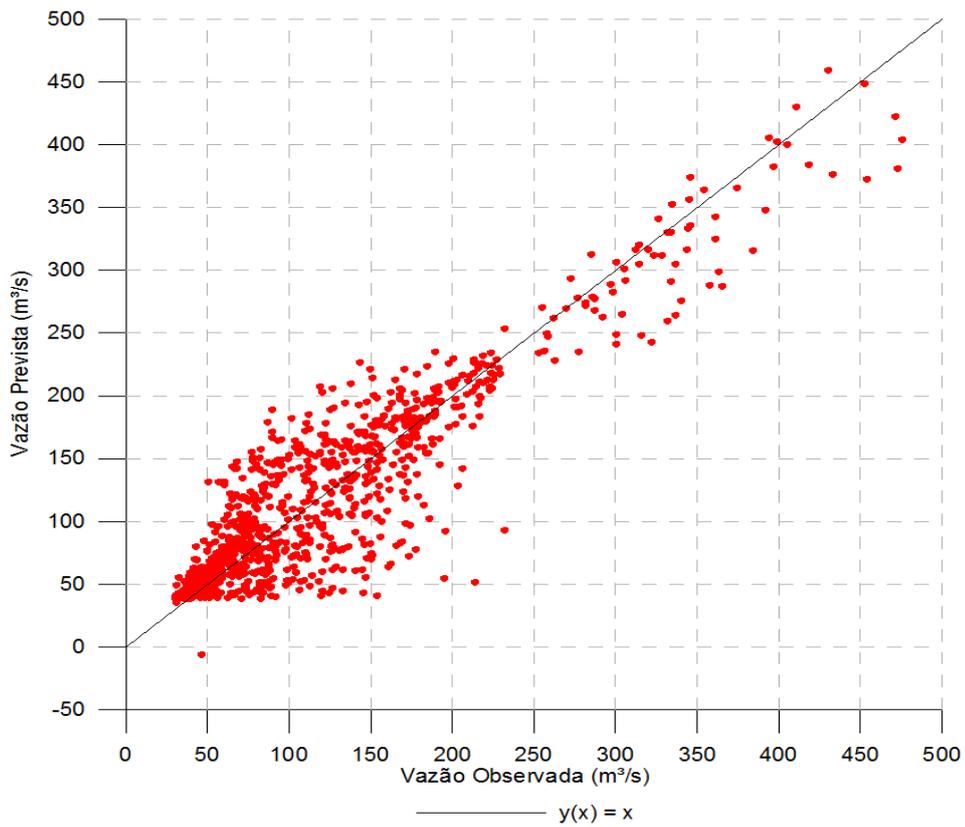


Figura 4.22 - Diagrama de dispersão com horizonte de 4 dias, experimento Q3N20

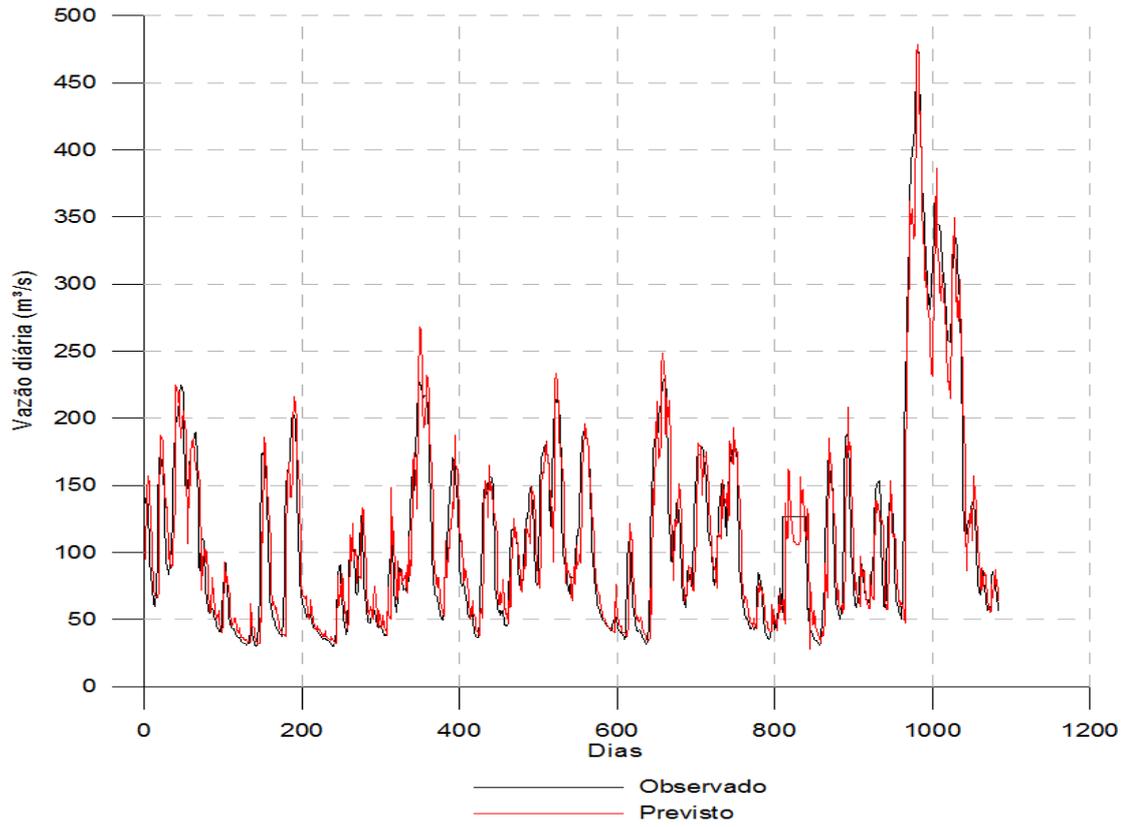


Figura 4.23 - Vazões observada e prevista pelo modelo, no experimento P5Q9N20, com horizonte de 4 dias

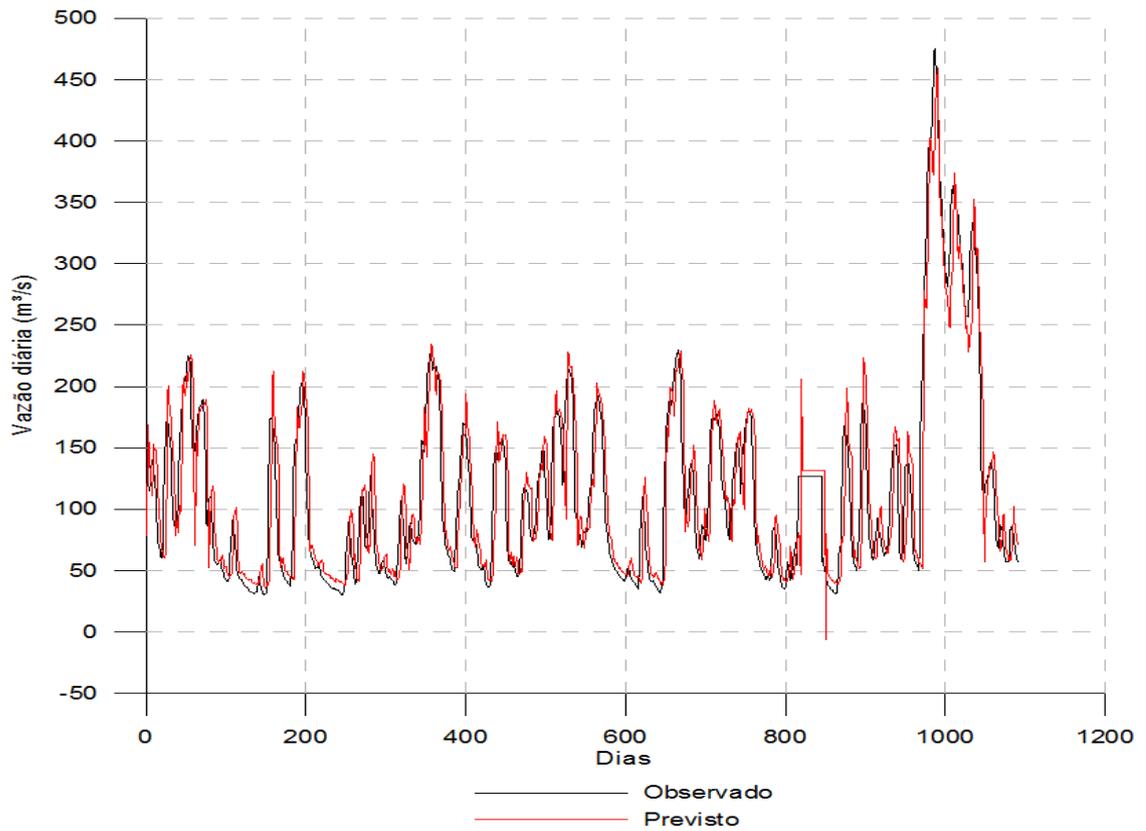


Figura 4.24 - Vazões observada e prevista pelo modelo, no experimento Q3N20, com horizonte de 4 dias

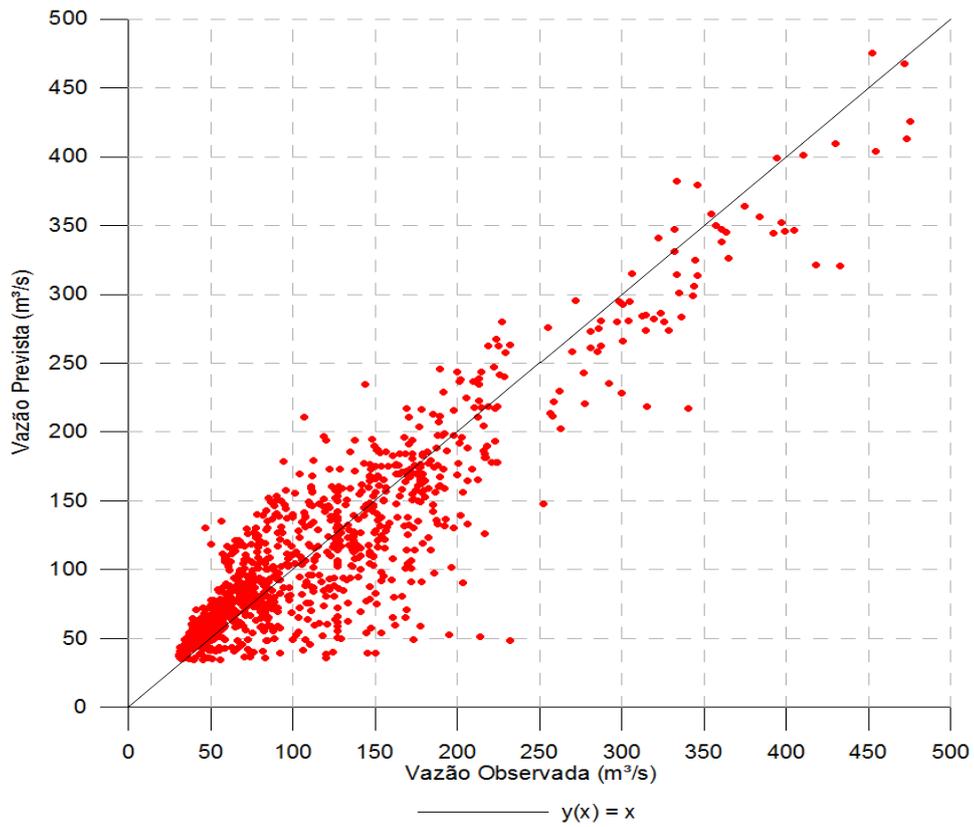


Figura 4.25 - Diagrama de dispersão com horizonte de 5 dias, experimento P5Q7N20

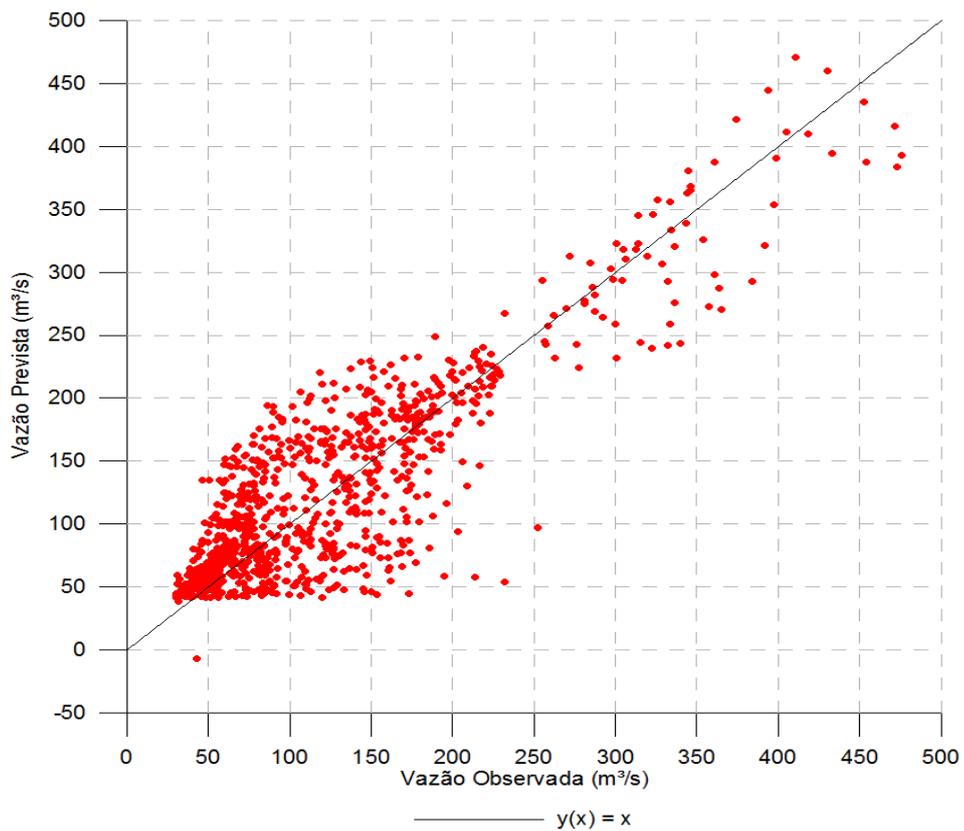


Figura 4.26 - Diagrama de dispersão com horizonte de 5 dias, experimento Q3N15

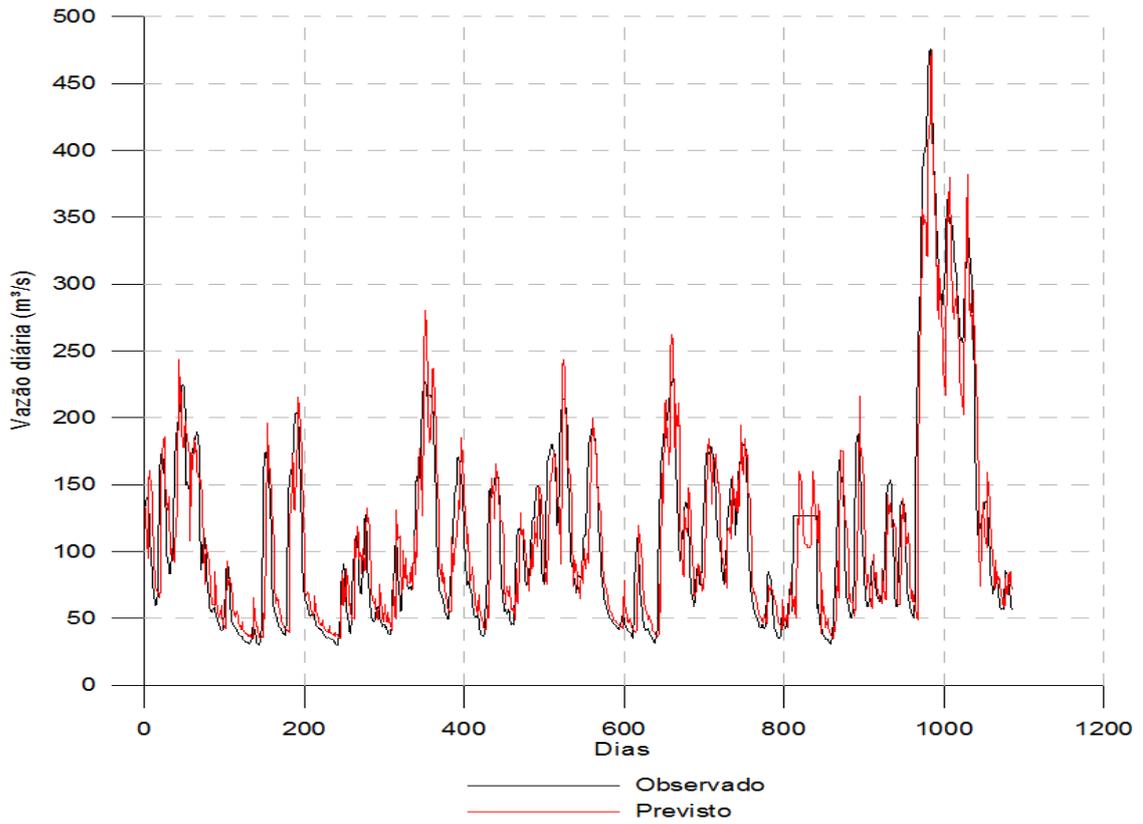


Figura 4.27 - Vazões observada e prevista pelo modelo, no experimento P5Q7N20, com horizonte de 5 dias

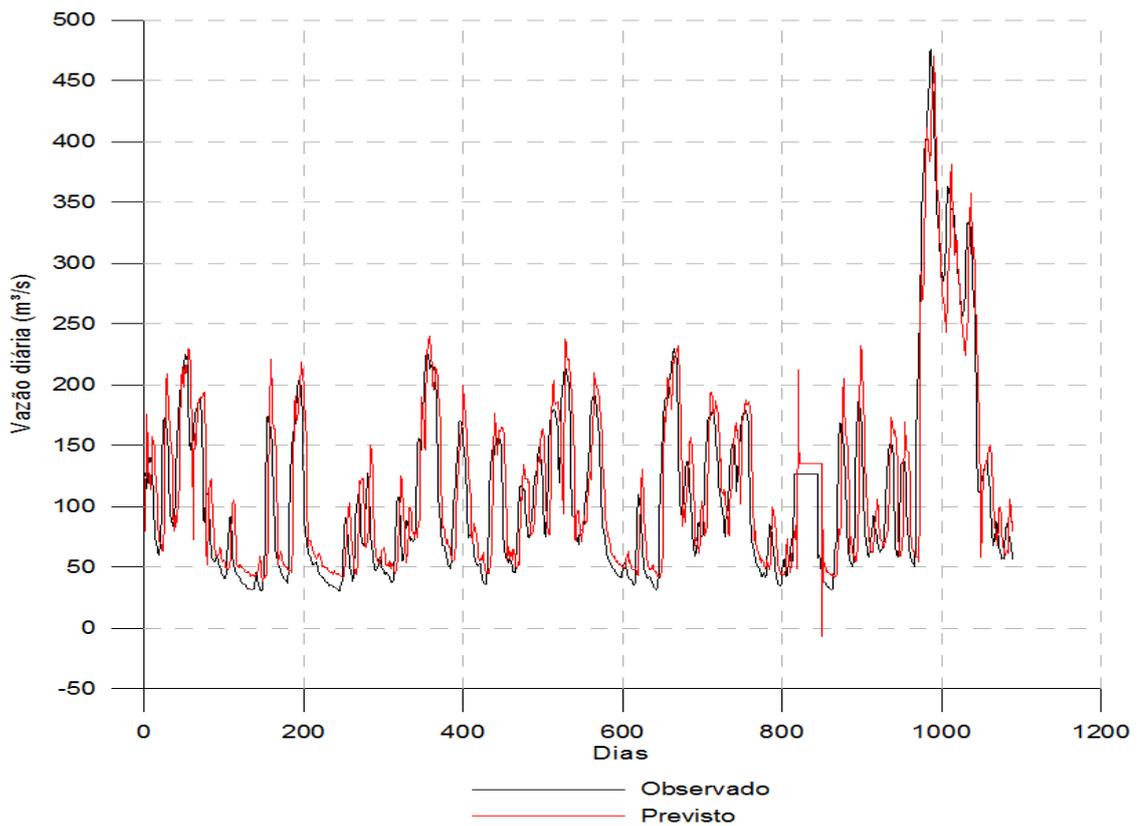


Figura 4.28 - Vazões observada e prevista pelo modelo, no experimento Q3N20, com horizonte de 5 dias

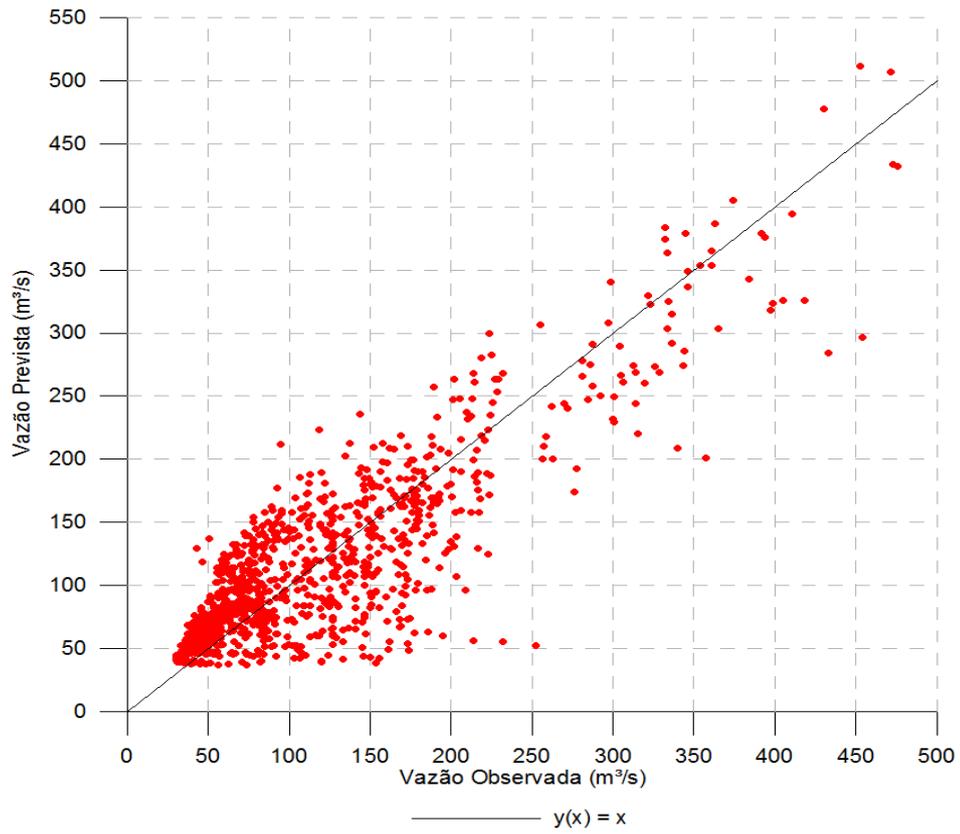


Figura 4.29 - Diagrama de dispersão com horizonte de 6 dias, experimento P5Q7N5

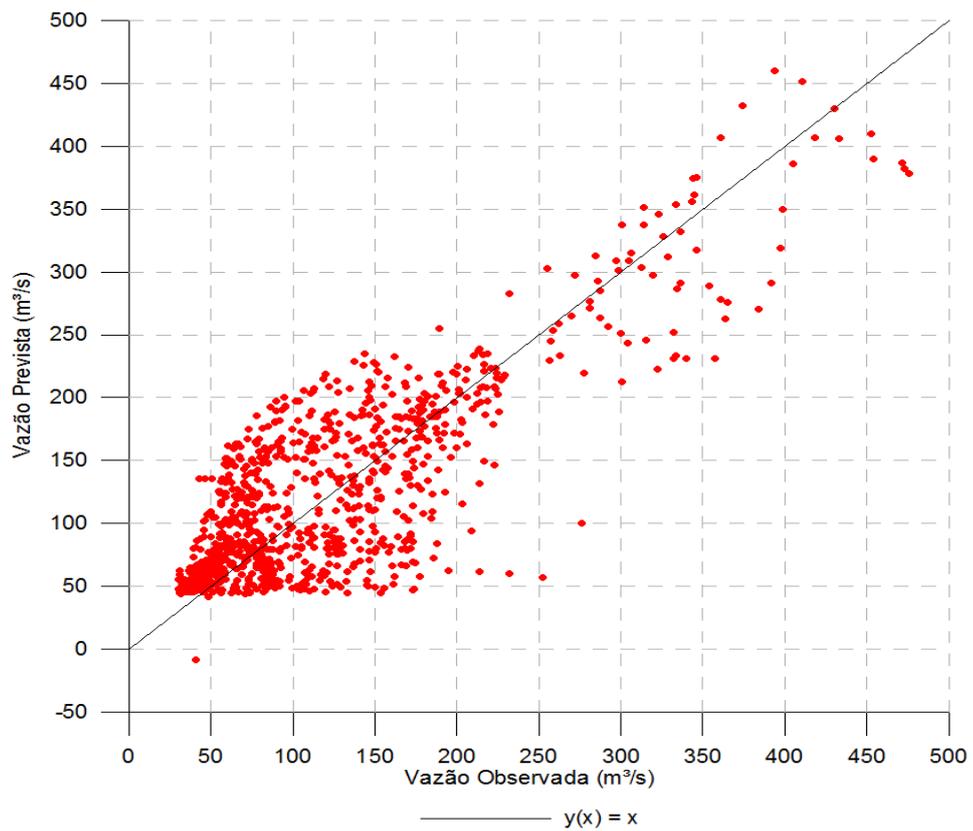


Figura 4.30 - Diagrama de dispersão com horizonte de 6 dias, experimento Q3N10

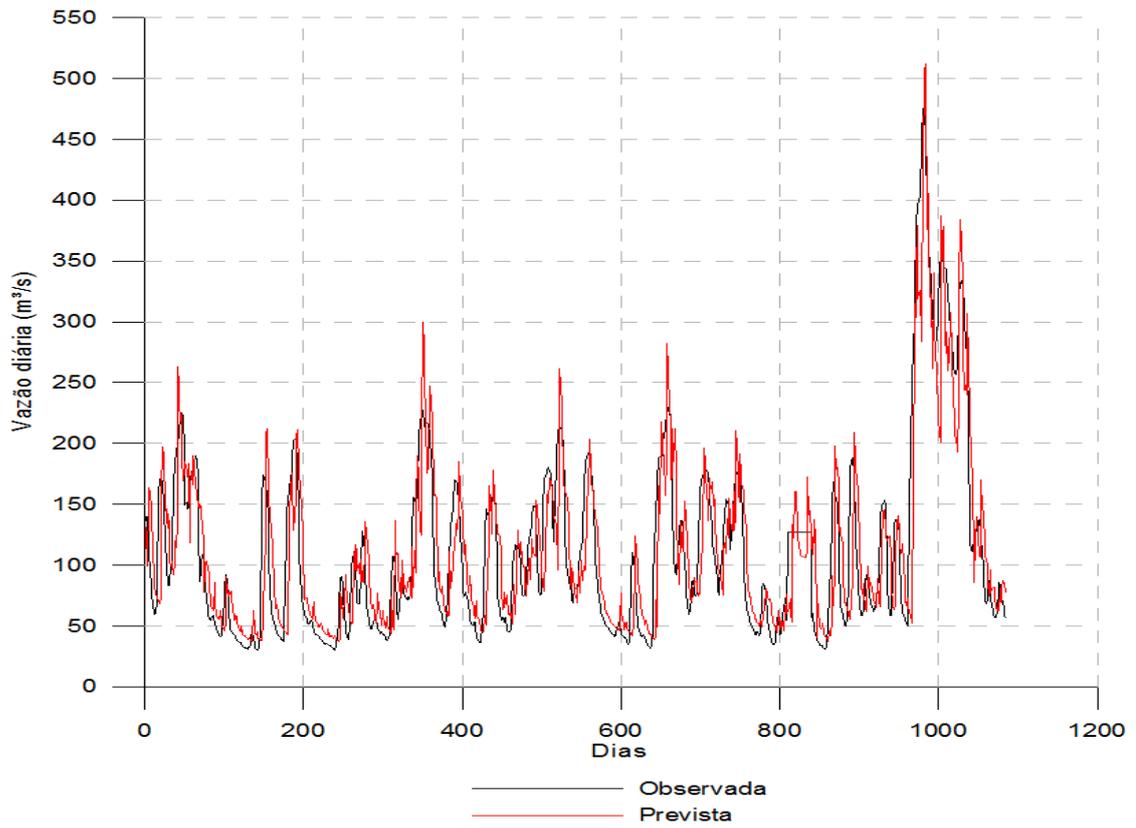


Figura 4.31 - Vazões observada e prevista pelo modelo, no experimento P5Q7N5, com horizonte de 6 dias

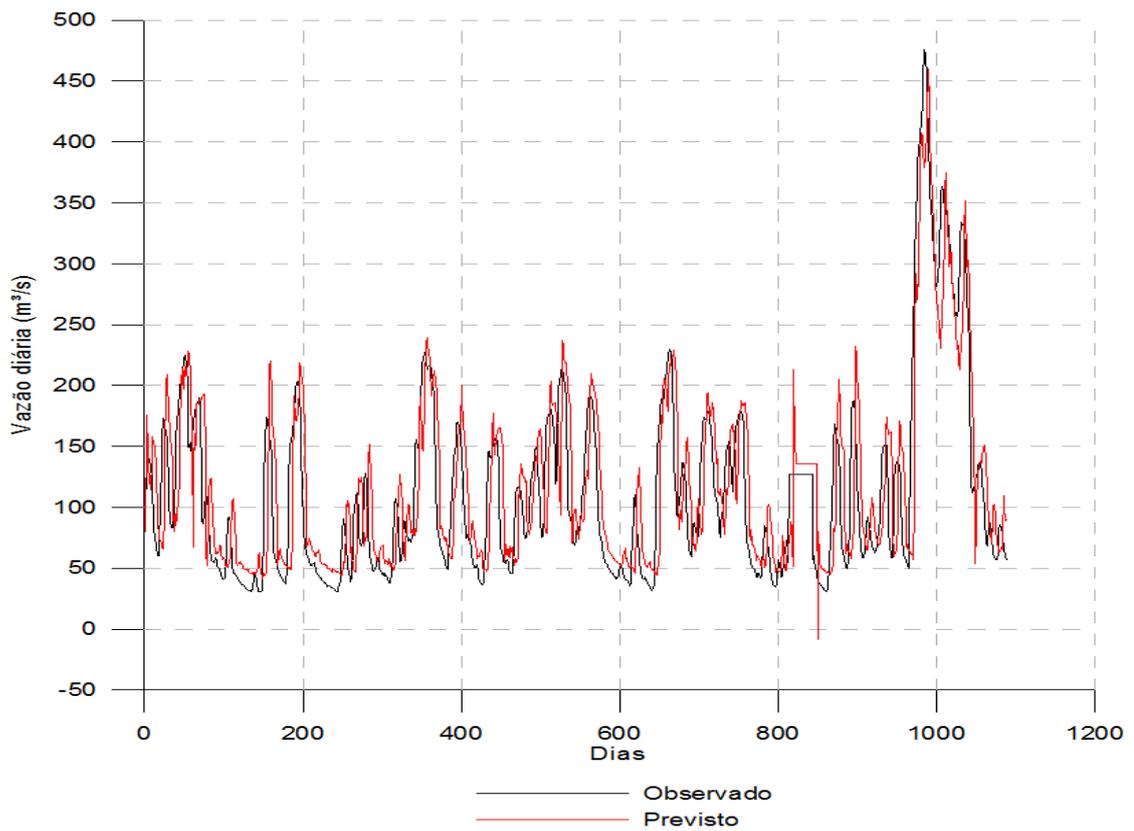


Figura 4.32 - Vazões observada e prevista pelo modelo, no experimento Q3N10, com horizonte de 6 dias

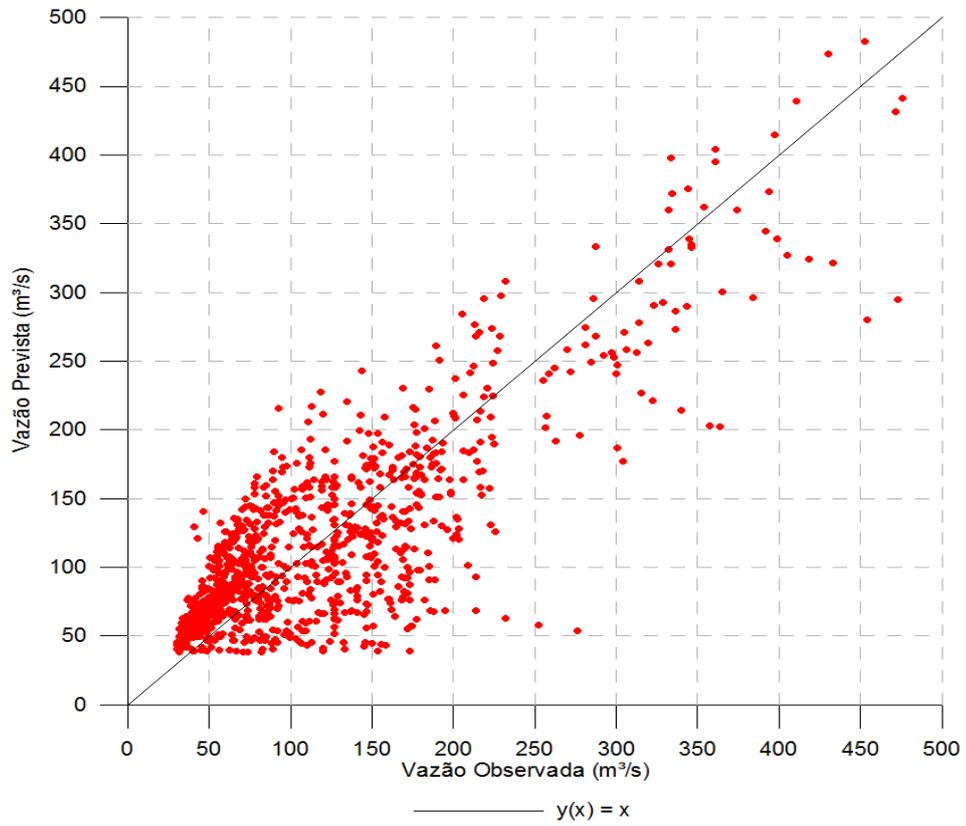


Figura 4.33 - Diagrama de dispersão com horizonte de 7 dias, experimento P5Q9N10

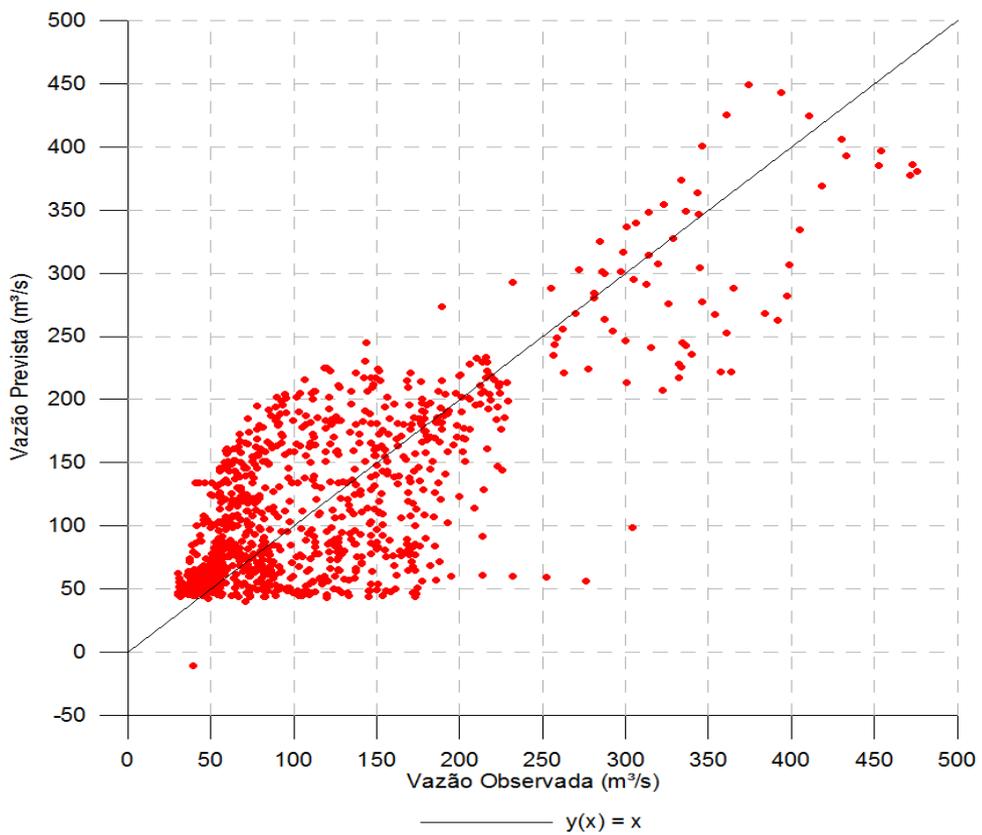


Figura 4.34 - Diagrama de dispersão com horizonte de 7 dias, experimento Q3N10

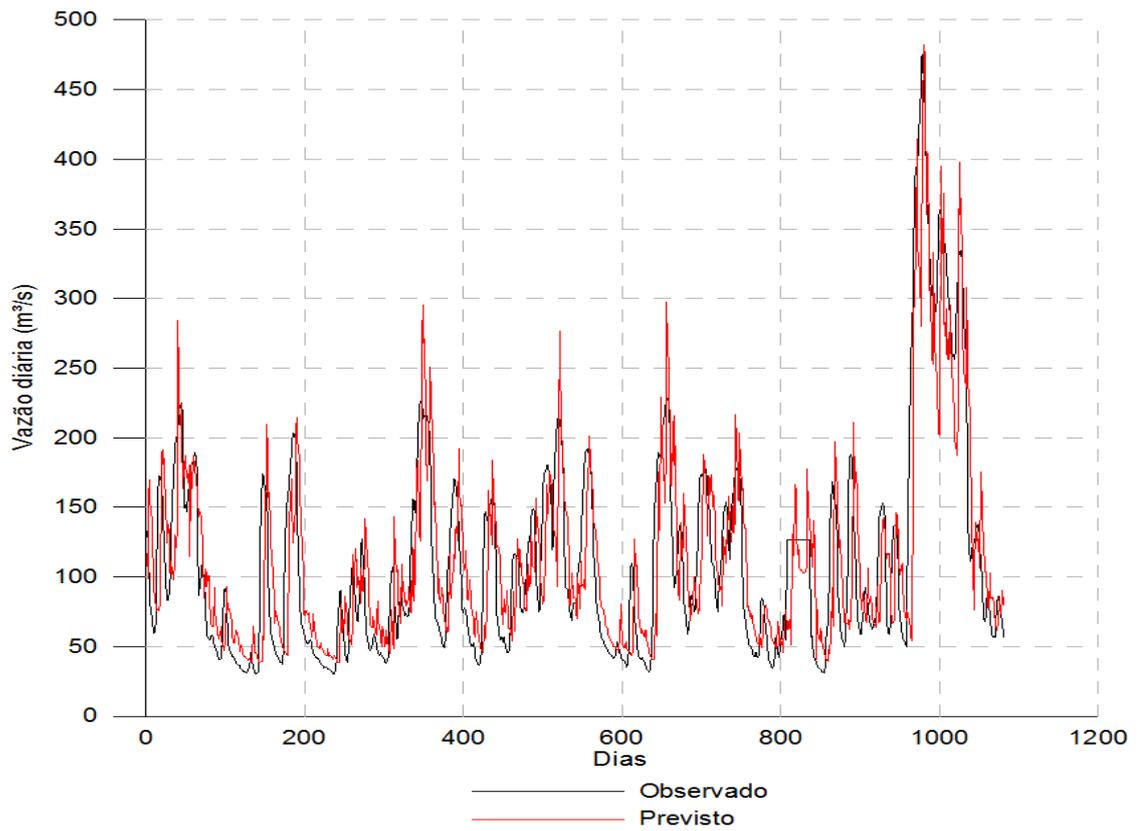


Figura 4.35 - Vazões observada e prevista pelo modelo, no experimento P5Q9N10, com horizonte de 7 dias

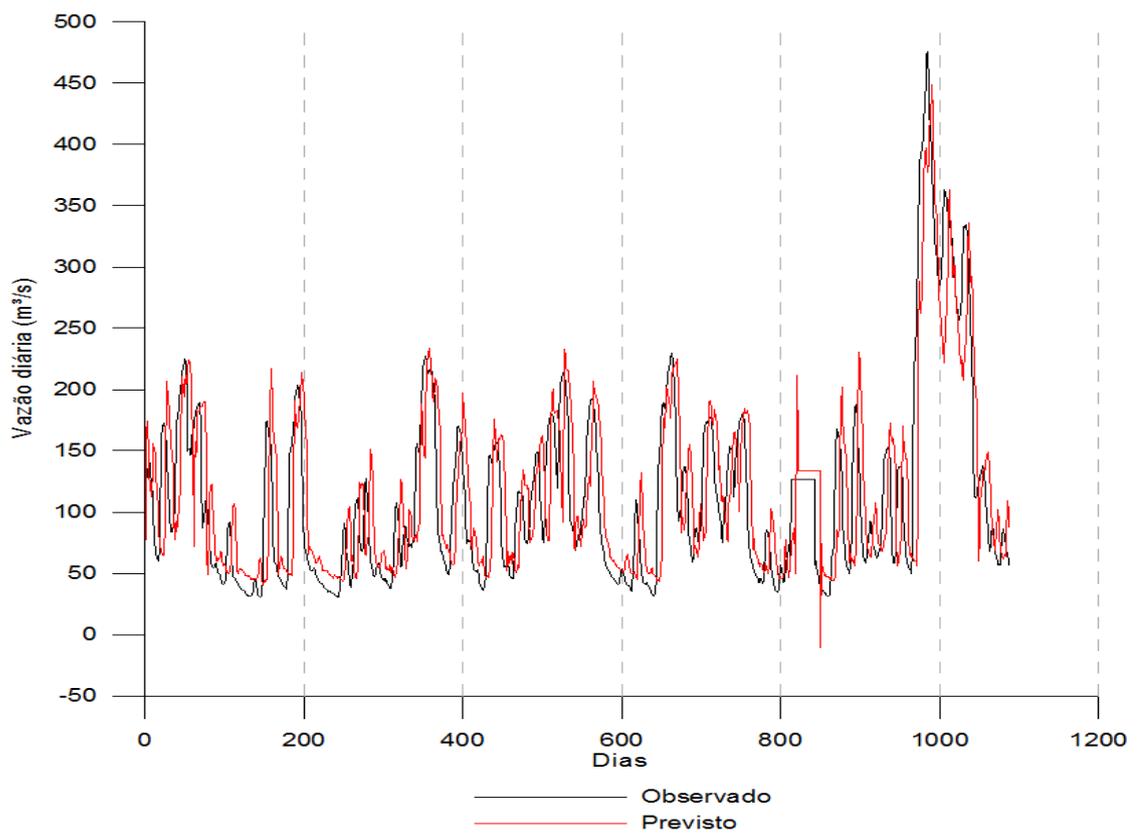


Figura 4.36 - Vazões observada e prevista pelo modelo, no experimento Q3N10, com horizonte de 7 dias

É importante ressaltar que como no trabalho de CABRAL (2013) e este aqui apresentado possuem metodologias diferentes, embora busquem apresentar resultados estatísticos similares, não podem ser comparados quantitativamente, buscando concluir qual rede irá apresentar um desempenho melhor. Entretanto, vale a pena a observação de alguns resultados obtidos para os mesmos horizontes de previsão, que permite uma comparação inicial dos resultados. Observando a tabela 4.2, é possível perceber que para todos os horizontes de previsão, a rede RBF apresentou resultados melhores do que a rede MLP para o coeficiente de Nash-Sutcliffe.

Fazendo uma análise quantitativa das previsões através das figuras 4.11, 4.12, 4.15, 4.16, 4.19, 4.20, 4.23, 4.24, 4.27, 4.28, 4.31, 4.32, 4.35 e 4.36 fica claro que conforme se avança no horizonte de previsão há um aumento no erro de fase da série prevista em relação à série observada. As series previstas contando apenas com vazões como dados de entrada tornam essa defasagem bastante evidente. Já nos experimentos que incluem precipitação, parece, visualmente, haver um maior ajuste das curvas observada e prevista, comprovado pelos valores de NASH sempre mais elevados quando comparados ao uso isolado de vazões. No trabalho de CABRAL (2013) este mesmo comportamento também foi observado. Ainda, tratando-se dos resultados destas figuras, é possível constatar que na faixa entre 800 e 1000 dias, onde havia uma falha nos dados observados, aparentemente a rede neural tentou realizar uma recuperação de série temporal. Aparentemente, a recuperação da série temporal foi bem sucedida, porém deve-se ressaltar que houveram oscilações nos resultados calculados, atingindo até valores de vazões negativas em alguns casos.

Os diagramas de dispersão apresentados nas figuras 4.9, 4.10, 4.13, 4.14, 4.17, 4.18, 4.21, 4.22, 4.25, 4.26, 4.29, 4.30, 4.33 e 4.34 indicam que existe uma tendência a subestimar as vazões maiores e superestimar os valores de vazão menores. Visualmente, todos os experimentos parecem subestimar os valores de vazão mais altos, não importando sua configuração. No trabalho de CABRAL (2013), a autora observou que a configuração que incluía dados de precipitação pretéritos apresentava uma maior tendência a subestimar os resultados previstos.

Como já mencionado na seção 3.4, existe uma falha de 30 dias na série de vazões, correspondente ao mês de abril de 2005. Analisando as figuras que apresentam as curvas observada e prevista, é possível notar esta falha entre os dias 800 e 1000. Em certos casos, como nas figuras 4.32 e 4.36, a rede chegou a prever resultados de vazão negativa, justamente por

causa deste período de 30 dias onde a vazão inserida manualmente era constante e com valor de 126.8 m³/s. No entanto, é possível perceber a rede apresentou uma resposta diferente para cada tipo de configuração apresentada para ela, em todos os horizontes de previsão. Na configuração que apresenta valores de vazão e precipitação pretéritos, os resultados previstos oscilam entre picos acima e abaixo da linha constante de valores observados. Já para a outra configuração que apresenta apenas dados de vazão pretérita, é possível perceber que existe um grande pico no início e fim do período de 30 dias, enquanto que ao longo dos dias analisados os resultados previstos são constantes.

4.2 Análise das vazões extremas

As grandes enchentes são uma das maiores preocupações dos conglomerados urbanos atualmente, logo todo estudo que visa prever quando este tipo de evento extremo pode ocorrer tem um imenso valor social e econômico.

A dificuldade de prever valores de cheia em redes neurais artificiais deve-se, provavelmente, por apresentarem-se em número bastante reduzido em relação aos dados médios de vazão. A existência de poucos dados, proporcionalmente, para treinamento pode favorecer a aprendizagem do comportamento da bacia para os valores médios, dificultando, então, a aprendizagem e, conseqüentemente, a previsão de valores mais elevados e discrepantes. Assim, tomou-se a oportunidade de fazer uma análise estatística das vazões consideradas como extremas, ou seja, que são acima de 200 m³/s, como já explicado na seção 3.3 anteriormente. Esta parte do trabalho não tem como objetivo realizar uma comparação com o trabalho de CABRAL (2013), mas sim para obter mais informações sobre o desempenho da rede com este tipo resultado.

A tabela 4.3 contém todos os valores estatísticos para os índices de NASH, RMS e MAD, referentes a todos os horizontes de previsão. Considerando uma análise dos índices entre as tabelas 4.3 e 4.2, é possível notar que os índices de Nash-Sutcliffe são relativamente equiparáveis até as previsões com 4 dias de horizonte. Para os mesmos 4 dias de horizonte, os valores de RMS também são próximos, o que indica que a variabilidade do erro entre as curvas das vazões observadas e previstas é similar para ambos os casos analisados. Para os horizontes de previsão seguintes, existe um grande decaimento nos valores dos índices que avaliam as vazões extremas, sendo que as previsões para o sexto e sétimo horizonte são julgadas como inaceitáveis (ASCE, 1993).

Tabela 4.3 - Índices de qualidade para a operação com as vazões extremas, para todos os horizontes de previsão.

Previsão com horizonte de 1 dia	Tipo de Rede	Rede RBF	
	Configuração	Q3N20	P5Q9N5
	NASH	0.99	0.99
	RMS (m ³ /s)	6.86	6.17
	MAD (m ³ /s)	4.46	5.46
Previsão com horizonte de 2 dias	Tipo de Rede	Rede RBF	
	Configuração	Q3N25	P5Q7N10
	NASH	0.97	0.97
	RMS (m ³ /s)	12.88	13.41
	MAD (m ³ /s)	9.38	11.01
Previsão com horizonte de 3 dias	Tipo de Rede	Rede RBF	
	Configuração	Q3N5	P5Q7N20
	NASH	0.88	0.92
	RMS (m ³ /s)	25.38	20.81
	MAD (m ³ /s)	16.91	17.12
Previsão com horizonte de 4 dias	Tipo de Rede	Rede RBF	
	Configuração	Q3N20	P5Q9N20
	NASH	0.75	0.79
	RMS (m ³ /s)	37.13	34.21
	MAD (m ³ /s)	16.91	17.12
Previsão com horizonte de 5 dias	Tipo de Rede	Rede RBF	
	Configuração	Q3N15	P5Q7N20
	NASH	0.61	0.59
	RMS (m ³ /s)	46.60	47.38
	MAD (m ³ /s)	31.97	36.37
Previsão com horizonte de 6 dias	Tipo de Rede	Rede RBF	
	Configuração	Q3N10	P5Q7N5
	NASH	0.41	0.33
	RMS (m ³ /s)	57.22	60.98
	MAD (m ³ /s)	40.56	47.62

Previsão com horizonte de 7 dias	Tipo de Rede	Rede RBF	
	Configuração	Q3N10	P5Q9N10
	NASH	0.16	0.12
	RMS (m ³ /s)	68.09	69.66
	MAD (m ³ /s)	49.63	53.93

5 CONCLUSÃO

O objetivo deste trabalho foi comparar o desempenho de dois tipos de redes neurais artificiais diferentes. Todos os resultados estatísticos apresentados pela rede RBF foram apresentados neste trabalho, e os principais resultados encontrados por CABRAL (2013) foram inseridos para uma melhor visualização entre os resultados. Além disso, foi realizada uma análise mais aprofundada dos valores de vazão considerados como extremos, utilizando-se da rede RBF.

Observando os resultados obtidos na fase de treinamento e operação, nota-se que existem certas configurações que aparecem repetidas vezes para o caso das redes RBF, alternando apenas o número de neurônios nas camadas intermediárias. Além disso é notável, através das figuras 4.1 a 4.7, que a inclusão de dados de precipitação traz uma melhoria no modelo de previsão de vazão para redes RBF. Para configuração que contém apenas dados de vazão, Q3 parece fornecer o melhor resultado independente do horizonte analisado. Para a segunda configuração de dados de entrada, envolvendo precipitação e vazão pretéritos, P5Q7 e P5Q9 são as combinações que mais apresentaram resultados mais positivos com relação ao índice de Nash-Sutcliffe. É possível notar, através da tabela 4.2, que a rede RBF apresentou índices de Nash-Sutcliffe ligeiramente maiores que a rede MLP, em números, a rede RBF apresentou um coeficiente de Nash-Sutcliffe aproximadamente 8% maior que a rede MLP, considerando uma média de todos os horizontes de previsão analisados com os seus melhores casos, respectivamente. Porém, devido as diferentes metodologias aplicadas nos trabalhos com as redes neurais artificiais, não é possível concluir qual rede de fato possui um desempenho melhor, sendo que ambas apresentaram resultados satisfatórios.

Segundo CABRAL (2013), um problema recorrente que foi observado em outros trabalhos similares envolvendo previsão de vazão é a defasagem da vazão prevista em relação a vazão observada, ao longo dos horizontes de previsão. Ainda, de acordo com a autora, a inserção da precipitação pretérita pareceu atenuar o problema de defasagem, todavia não o

solucionou. Esta mesma defasagem ocorreu nos diferentes horizontes de previsão para a rede RBF, sendo que a inclusão da precipitação também se mostrou eficaz para diminuir o problema.

Conforme DORNELLES *et al* (2006, apud CABRAL, 2013), a subestimação de valores de vazão muito elevados e a superestimação de valores de vazão muito pequenos de vazão é comum durante as previsões utilizando redes neurais. No trabalho de CABRAL (2013), é visualmente perceptível a subestimação das vazões nos valores mais extremos. Para o caso da rede RBF, este mesmo subdimensionamento também ocorre nos valores mais altos de vazão. Porém, visualmente, é mais provável que os valores previstos pela rede RBF consigam se aproximar mais dos valores observados durante os instantes com vazões mais altas.

Por fim, quanto aos índices de qualidade obtidos para as vazões extremas, é possível concluir que a rede não é capaz de fornecer um resultado confiável para o sexto e sétimo horizontes de previsão, levando em conta os valores obtidos para o índice de Nash-Sutcliffe. Quanto aos outros horizontes de previsão, especificamente o primeiro, a rede é capaz de fornecer uma previsão com boa qualidade, apresentando um coeficiente de Nash-Sutcliffe igual a 0.97, apesar de apresentar o índice RMS com aproximadamente o dobro do valor previsto no modelo de vazão global.

Dada a importância de se prever os valores extremos de vazão, seria interessante, como sugestão para trabalhos futuros, avaliar o desempenho da rede neural realizando o treinamento da rede apenas com os valores extremos de vazão. Também, como sugestão para futuros trabalhos, seria interessante adicionar mais dados de precipitação pretérita nos experimentos, para avaliar se o índice de Nash-Sutcliffe aumenta gradativamente com a inclusão de mais dados de precipitação. Por fim, uma outra sugestão seria avaliar a relevância da evaporação como dado de entrada na rede neural. Na falta de dados de evaporação, poderia ser utilizado dados que se relacionam diretamente com ela, como temperatura e umidade relativa, dentre outros, de mais fácil obtenção.

6 REFERÊNCIAS BIBLIOGRÁFICAS

American Society of Civil Engineers (ASCE). Task Committee on Definition of Criteria for Evaluation of Watershed Models of the Watershed Management Committee, Irrigation and Drainage Division. Criteria for evaluation of water shed models. J. Irrig. Drainage Eng., 119:429-442, 1993.

BATISTA, M.S. Ciclo Hidrológico: Interceptação. Dissertação (Mestrado) – UFCG, 2010.

BLAKE, G. J. The interception process. Prediction in catchment hydrology. Australian Academy of Science, 1975.

BRAGA, A., P; CARVALHO, A., P., L; LUDERMIR, T., B. Redes Neurais Artificiais: Teoria e Aplicações. 2ª ed. LTC, Rio de Janeiro, 2011.

CABRAL, I. G. Previsões de vazão diária para a bacia do Alto Iguaçu com o emprego de redes neurais artificiais. Trabalho de Conclusão de Curso - Universidade Federal do Paraná, Curitiba, 2013.

CARDOSO, S. H. Comunicação entre as células nervosas, 2000. Disponível em:
<http://www.cerebromente.org.br/n12/fundamentos/neurotransmissores/neurotransmitters2_p.html>. Acesso em 29/04/2016

CARVALHO, D.F; SILVA, L.D.B. Apostila de Hidrologia. Rio de Janeiro, Universidade Federal Rural do Rio de Janeiro, 2003.

CPC – Climate Prediction Center. Disponível em:
<<http://www.cpc.ncep.noaa.gov/>>. Acesso em 05/03/2013

CHOW, V.T., MAIDMENT, D. R., MAYS, L. W.. Applied Hydrology, McGraw-Hill. 1988.

CYBENKO, G. Approximation by superposition of a sigmoid function. Mathematics of Control, Signals and Systems, v.2, p. 303-314, 1989.

DUDA, R.O., HART, P.E., STORK, D.G.; Pattern Classification. New York: Wiley Interscience, 2001.

FAYAL, M. A. de A. Previsão de Vazão por Redes Neurais Artificiais e Transformada Wavelet. Dissertação (Mestrado) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2008.

FRITSCH, S.; GÜNTHER, F.; Neural Net: Training of Neural Networks. R. News, v.1, n.2, p. 30-38, 2010.

HALDAR, A.; MAHADEVAN, S. Probability, Reliability and Statistical Methods in Engineering Design. New York: Wiley Interscience, 2000.

HARPHAM, C., WILBY, R. L. “Multi-site of daily precipitation amounts using Artificial Neural Networks”, Hydrology: Science & Practice for de 21st Century, Vol. 1, pp. 128 – 138, British Hydrological Society, 2004.

HAYKIN, S. Redes Neurais: Princípios e Prática. 2ªed. Bookman, Porto Alegre, 2001.

HIDROWEB. Sistema de Informações Hidrológicas. Disponível em:
<<http://hidroweb.ana.gov.br/>>. Acesso em 05/03/2013.

HSU, K.L.; GUPTA, H.V.; SOROOSHIAN, S. Artificial neural network modeling of the rainfall-runoff process. Water Resources Research, v. 31, n.10, p.2517-2530, 1995.

IRWAN, A.N.; SOBRI, H.; HASHIM, M.K.; 2007. Radial basis function modeling of hourly streamflow hydrograph. Journal of Hydrologic Engineering, p. 113-123, 2007.

KUMAR, M.; BANDYOPADHYAY, A.; RAGHUWANSHI, N. S.; SINGH, R. Comparative Study Of Conventional And Artificial Neural Network-based Estimation Models. Irrigation Science, v.26, n.6, p.531-545, 2008.

LINSLEY JR, R. K.; KOHLER, M. A.; PAULHUS, J. L. H. Hydrology for Engineers. 2ª ed. McGraw Hill Book, New York, 1975.

MACHADO, F. W. Modelagem Chuva-Vazão Mensal Utilizando Redes Neurais Artificiais. Dissertação (Mestrado) – Universidade Federal do Paraná, Curitiba, 2005.

MCCULLOCH, W. S.; PITTS, W.; A Logical Calculus Of The Ideas Immanent In Nervous Activity Bulletin of Mathematical Biophysics, p. 115-133, 1943

NITRINI, R.; BACHESCHI, L. A.; A Neurologia que todo médico deve saber. 2. ed. São Paulo: Editora Atheneu, v. 1, 2008

ONS. Operador Nacional do Sistema Elétrico. Disponível em:

<www.ons.org.br>. Acesso em 22/02/2016.

ROSENBLATT, F. The perceptron: probabilistic model for information storage and organization in the brain. Psychological Review, p. 386–408, 1958.

SANTOS, Cláudia C. Modelagem de Bacias Urbanas com Redes Neurais Artificiais, 2001. Dissertação (Mestrado) – USP, São Paulo.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.; Redes neurais artificiais: para engenharia e ciências aplicadas. Artliber, São Paulo, 2010.

SUDERHSA. Plano da bacia do Alto Iguaçu e afluentes do Alto Ribeira, 2007. Disponível em: <<http://www.aguasparana.pr.gov.br/>>. Acesso em 15/02/2016.

APÊNDICE A

Este capítulo apresenta as tabelas com os índices de qualidade obtidos durante o treinamento da rede.

Tabela A.1: Índices de qualidade para treinamento da rede para previsão com horizonte de 1 dia

Experimento	Configuração	RMS(m ³ /s)	NASH	MAD (m ³ /s)
1	Q1N05	27.66	0.94	9.23
2	Q1N10	28.68	0.93	9.19
3	Q1N15	27.79	0.94	9.15
4	Q1N20	26.75	0.94	9.18
5	Q1N25	29.51	0.93	9.50
6	Q3N05	24.89	0.95	7.08
7	Q3N10	24.02	0.94	6.31
8	Q3N15	24.57	0.94	6.40
9	Q3N20	23.26	0.95	6.19
10	Q3N25	24.83	0.94	6.25
11	Q5N05	26.78	0.94	7.72
12	Q5N10	28.37	0.93	6.96
13	Q5N15	28.65	0.93	6.91
14	Q5N20	26.43	0.94	6.75
15	Q5N25	28.97	0.93	7.02
16	Q7N05	26.30	0.94	7.67
17	Q7N10	30.30	0.92	7.27
18	Q7N15	31.32	0.92	7.20
19	Q7N20	27.81	0.93	7.29
20	Q7N25	33.34	0.91	7.62
21	Q9N05	28.60	0.93	7.93
22	Q9N10	31.22	0.91	7.33
23	Q9N15	29.31	0.92	7.18
24	Q9N20	27.22	0.94	7.09
25	Q9N25	28.02	0.93	7.19
26	P1Q1N05	230.77	-11.48	214.25
27	P1Q1N10	25.37	0.95	8.93
28	P1Q1N15	25.23	0.95	8.86
29	P1Q1N20	27.11	0.94	8.82
30	P1Q1N25	27.54	0.93	8.62
31	P1Q3N05	29.35	0.92	7.30
32	P1Q3N10	26.09	0.93	6.58
33	P1Q3N15	26.12	0.93	6.37
34	P1Q3N20	27.68	0.92	6.44
35	P1Q3N25	24.50	0.94	6.32
36	P1Q5N05	26.01	0.95	7.70
37	P1Q5N10	26.95	0.93	7.30
38	P1Q5N15	25.67	0.94	7.12
39	P1Q5N20	26.00	0.94	6.91
40	P1Q5N25	25.55	0.94	6.69
41	P1Q7N05	25.49	0.95	7.96
42	P1Q7N10	28.33	0.92	7.18

43	P1Q7N15	25.32	0.94	7.16
44	P1Q7N20	28.69	0.93	7.09
45	P1Q7N25	25.89	0.94	7.01
46	P1Q9N05	59.73	0.70	24.83
47	P1Q9N10	58.57	0.72	24.54
48	P1Q9N15	59.54	0.71	23.86
49	P1Q9N20	58.60	0.72	23.65
50	P1Q9N25	57.85	0.72	22.95
51	P3Q1N05	29.87	0.93	10.18
52	P3Q1N10	29.94	0.92	8.71
53	P3Q1N15	28.45	0.92	8.45
54	P3Q1N20	28.43	0.93	8.63
55	P3Q1N25	27.95	0.92	8.61
56	P3Q3N05	26.14	0.94	7.36
57	P3Q3N10	25.47	0.94	6.95
58	P3Q3N15	26.67	0.93	6.89
59	P3Q3N20	27.95	0.93	6.72
60	P3Q3N25	28.20	0.92	6.97
61	P3Q5N05	26.83	0.94	8.27
62	P3Q5N10	29.17	0.93	8.02
63	P3Q5N15	29.02	0.93	7.61
64	P3Q5N20	26.66	0.94	7.12
65	P3Q5N25	27.09	0.94	7.15
66	P3Q7N05	26.52	0.94	8.42
67	P3Q7N10	26.52	0.94	8.42
68	P3Q7N15	25.55	0.95	7.15
69	P3Q7N20	27.96	0.93	7.29
70	P3Q7N25	27.84	0.93	7.18
71	P3Q9N05	28.90	0.93	7.35
72	P3Q9N10	28.82	0.92	8.05
73	P3Q9N15	28.72	0.93	7.65
74	P3Q9N20	28.75	0.93	7.83
75	P3Q9N25	27.17	0.94	7.33
76	P5Q1N05	26.30	0.94	8.72
77	P5Q1N10	27.82	0.94	8.52
78	P5Q1N15	34.03	0.87	8.39
79	P5Q1N20	32.84	0.89	8.24
80	P5Q1N25	34.07	0.89	8.19
81	P5Q3N05	26.18	0.94	7.15
82	P5Q3N10	27.04	0.94	7.02
83	P5Q3N15	26.07	0.94	6.76
84	P5Q3N20	27.28	0.93	6.76
85	P5Q3N25	27.30	0.93	6.77
86	P5Q5N05	26.21	0.94	7.80
87	P5Q5N10	24.96	0.94	6.66
88	P5Q5N15	25.52	0.94	6.63
89	P5Q5N20	25.70	0.94	6.51
90	P5Q5N25	26.45	0.94	6.75

91	P5Q7N05	24.96	0.94	6.66
92	P5Q7N10	25.52	0.94	6.63
93	P5Q7N15	27.18	0.93	6.89
94	P5Q7N20	26.38	0.94	6.66
95	P5Q7N25	26.62	0.94	6.69
96	P5Q9N05	24.84	0.95	7.37
97	P5Q9N10	25.65	0.94	6.72
98	P5Q9N15	26.65	0.94	6.70
99	P5Q9N20	26.65	0.94	6.70
100	P5Q9N25	26.76	0.94	6.82

Tabela A.2: Índices de qualidade para treinamento da rede para previsão com horizonte de 2 dias

Experimento	Configuração	RMS(m ³ /s)	NASH	MAD
1	Q1N05	39.92	0.88	17.36
2	Q1N10	40.63	0.87	17.28
3	Q1N15	40.56	0.87	17.32
4	Q1N20	40.48	0.87	17.28
5	Q1N25	40.16	0.88	17.22
6	Q3N05	35.46	0.90	13.30
7	Q3N10	35.38	0.90	12.77
8	Q3N15	40.39	0.86	12.83
9	Q3N20	35.60	0.90	12.69
10	Q3N25	34.50	0.91	12.61
11	Q5N05	33.80	0.90	12.64
12	Q5N10	36.01	0.90	13.46
13	Q5N15	36.15	0.90	13.57
14	Q5N20	36.91	0.89	13.70
15	Q5N25	36.66	0.90	13.45
16	Q7N05	36.78	0.89	14.91
17	Q7N10	35.95	0.90	14.36
18	Q7N15	37.36	0.88	14.39
19	Q7N20	36.54	0.89	14.98
20	Q7N25	41.38	0.86	15.10
21	Q9N05	39.75	0.88	15.32
22	Q9N10	40.23	0.87	14.23
23	Q9N15	39.76	0.88	14.16
24	Q9N20	37.16	0.89	13.88
25	Q9N25	39.24	0.88	14.29
26	P1Q1N05	39.41	0.88	16.02
27	P1Q1N10	39.89	0.87	15.72
28	P1Q1N15	39.54	0.88	15.75
29	P1Q1N20	39.60	0.88	15.68
30	P1Q1N25	38.38	0.88	15.59
31	P1Q3N05	37.07	0.89	14.02
32	P1Q3N10	37.29	0.89	13.23
33	P1Q3N15	35.35	0.90	12.82
34	P1Q3N20	37.54	0.89	12.79

35	P1Q3N25	36.85	0.88	12.76
36	P1Q5N05	38.35	0.89	14.10
37	P1Q5N10	42.56	0.86	13.74
38	P1Q5N15	43.29	0.86	13.32
39	P1Q5N20	38.23	0.89	13.17
40	P1Q5N25	43.33	0.86	13.59
41	P1Q7N05	36.92	0.89	14.45
42	P1Q7N10	38.60	0.88	13.67
43	P1Q7N15	40.39	0.87	13.71
44	P1Q7N20	40.65	0.87	13.72
45	P1Q7N25	43.58	0.85	13.68
46	P1Q9N05	38.41	0.89	14.55
47	P1Q9N10	39.72	0.87	14.17
48	P1Q9N15	41.43	0.86	13.80
49	P1Q9N20	41.93	0.86	13.74
50	P1Q9N25	43.09	0.85	13.65
51	P3Q1N05	39.85	0.88	16.32
52	P3Q1N10	38.03	0.89	15.19
53	P3Q1N15	39.98	0.88	15.28
54	P3Q1N20	39.50	0.88	15.19
55	P3Q1N25	39.50	0.88	15.19
56	P3Q3N05	35.80	0.90	13.63
57	P3Q3N10	34.85	0.90	12.68
58	P3Q3N15	35.36	0.90	13.03
59	P3Q3N20	34.98	0.90	12.46
60	P3Q3N25	34.70	0.90	12.33
61	P3Q5N05	34.78	0.91	14.28
62	P3Q5N10	39.63	0.88	13.34
63	P3Q5N15	37.73	0.88	12.63
64	P3Q5N20	35.39	0.90	12.28
65	P3Q5N25	41.60	0.86	12.67
66	P3Q7N05	35.69	0.90	14.11
67	P3Q7N10	38.44	0.88	13.43
68	P3Q7N15	38.53	0.88	12.97
69	P3Q7N20	36.35	0.89	13.06
70	P3Q7N25	38.15	0.88	12.85
71	P3Q9N05	35.91	0.90	14.05
72	P3Q9N10	37.17	0.89	13.26
73	P3Q9N15	34.54	0.91	12.66
74	P3Q9N20	35.03	0.90	12.52
75	P3Q9N25	32.13	0.92	12.45
76	P5Q1N05	35.37	0.90	14.28
77	P5Q1N10	36.35	0.89	14.08
78	P5Q1N15	39.49	0.86	13.81
79	P5Q1N20	37.47	0.89	13.60
80	P5Q1N25	39.60	0.86	13.85
81	P5Q3N05	35.33	0.90	12.70
82	P5Q3N10	38.21	0.87	12.09

83	P5Q3N15	35.34	0.90	11.88
84	P5Q3N20	39.85	0.86	12.05
85	P5Q3N25	36.21	0.89	12.00
86	P5Q5N05	35.57	0.90	12.87
87	P5Q5N10	36.66	0.89	12.09
88	P5Q5N15	33.55	0.91	11.87
89	P5Q5N20	33.19	0.90	11.98
90	P5Q5N25	32.94	0.92	11.69
91	P5Q7N05	40.23	0.88	18.12
92	P5Q7N10	31.40	0.92	12.09
93	P5Q7N15	38.70	0.89	17.38
94	P5Q7N20	34.10	0.90	11.86
95	P5Q7N25	35.82	0.89	12.04
96	P5Q9N05	35.52	0.90	13.50
97	P5Q9N10	32.94	0.91	12.07
98	P5Q9N15	32.42	0.92	11.92
99	P5Q9N20	35.39	0.90	12.35
100	P5Q9N25	34.32	0.91	12.07

Tabela A.3: Índices de qualidade para treinamento da rede para previsão com horizonte de 3 dias

Experimento	Configuração	RMS(m ³ /s)	NASH	MAD
1	Q1N05	50.34	0.81	24.52
2	Q1N10	50.13	0.82	24.45
3	Q1N15	50.31	0.81	24.52
4	Q1N20	50.33	0.81	24.50
5	Q1N25	50.70	0.81	24.51
6	Q3N05	45.03	0.85	20.09
7	Q3N10	45.29	0.84	19.55
8	Q3N15	46.62	0.84	19.77
9	Q3N20	45.23	0.84	19.75
10	Q3N25	43.85	0.85	19.45
11	Q5N05	48.33	0.83	21.05
12	Q5N10	47.23	0.84	20.13
13	Q5N15	46.45	0.84	20.51
14	Q5N20	45.95	0.84	20.35
15	Q5N25	45.98	0.84	20.61
16	Q7N05	47.80	0.83	21.15
17	Q7N10	47.33	0.83	20.59
18	Q7N15	47.78	0.83	20.54
19	Q7N20	47.06	0.83	20.62
20	Q7N25	47.38	0.83	20.46
21	Q9N05	51.03	0.80	21.58
22	Q9N10	49.30	0.81	20.68
23	Q9N15	51.88	0.79	20.79
24	Q9N20	53.90	0.77	20.71
25	Q9N25	48.75	0.82	20.26
26	P1Q1N05	47.93	0.82	22.22

27	P1Q1N10	48.71	0.82	22.16
28	P1Q1N15	48.60	0.82	22.23
29	P1Q1N20	48.60	0.82	22.23
30	P1Q1N25	48.26	0.82	22.13
31	P1Q3N05	45.95	0.84	20.48
32	P1Q3N10	44.01	0.85	19.30
33	P1Q3N15	45.36	0.84	19.00
34	P1Q3N20	44.18	0.85	19.05
35	P1Q3N25	43.86	0.85	18.86
36	P1Q5N05	45.07	0.85	20.31
37	P1Q5N10	45.16	0.84	19.07
38	P1Q5N15	44.91	0.85	18.97
39	P1Q5N20	50.83	0.80	19.21
40	P1Q5N25	51.35	0.79	19.48
41	P1Q7N05	45.21	0.84	20.41
42	P1Q7N10	47.72	0.83	19.65
43	P1Q7N15	49.92	0.81	19.89
44	P1Q7N20	51.51	0.79	19.93
45	P1Q7N25	50.61	0.80	19.97
46	P1Q9N05	47.68	0.83	21.02
47	P1Q9N10	47.04	0.83	20.06
48	P1Q9N15	48.88	0.82	19.75
49	P1Q9N20	46.36	0.83	19.49
50	P1Q9N25	46.85	0.83	19.66
51	P3Q1N05	48.03	0.82	21.41
52	P3Q1N10	49.69	0.81	20.82
53	P3Q1N15	46.39	0.83	20.94
54	P3Q1N20	50.39	0.79	20.81
55	P3Q1N25	48.98	0.82	20.77
56	P3Q3N05	44.50	0.85	19.56
57	P3Q3N10	43.21	0.86	18.60
58	P3Q3N15	43.51	0.86	17.97
59	P3Q3N20	41.05	0.87	17.80
60	P3Q3N25	42.08	0.87	17.85
61	P3Q5N05	42.73	0.87	19.26
62	P3Q5N10	41.00	0.88	18.89
63	P3Q5N15	38.50	0.89	18.03
64	P3Q5N20	38.64	0.89	17.97
65	P3Q5N25	39.48	0.88	17.88
66	P3Q7N05	42.55	0.87	19.58
67	P3Q7N10	43.37	0.86	18.78
68	P3Q7N15	40.93	0.88	18.12
69	P3Q7N20	43.35	0.86	18.30
70	P3Q7N25	42.90	0.86	17.93
71	P3Q9N05	42.68	0.86	19.60
72	P3Q9N10	41.57	0.87	18.95
73	P3Q9N15	38.50	0.89	18.02
74	P3Q9N20	42.87	0.86	18.31

75	P3Q9N25	39.94	0.88	18.09
76	P5Q1N05	41.63	0.87	19.57
77	P5Q1N10	41.83	0.87	19.36
78	P5Q1N15	40.88	0.87	19.02
79	P5Q1N20	41.14	0.87	18.85
80	P5Q1N25	41.35	0.87	18.95
81	P5Q3N05	39.26	0.89	17.89
82	P5Q3N10	39.47	0.88	17.48
83	P5Q3N15	38.10	0.89	17.35
84	P5Q3N20	37.68	0.90	17.18
85	P5Q3N25	39.14	0.89	17.19
86	P5Q5N05	39.52	0.88	17.97
87	P5Q5N10	37.89	0.89	17.21
88	P5Q5N15	38.28	0.89	17.27
89	P5Q5N20	37.26	0.90	17.07
90	P5Q5N25	37.39	0.90	17.29
91	P5Q7N05	39.19	0.89	17.71
92	P5Q7N10	37.73	0.89	17.23
93	P5Q7N15	37.77	0.89	17.21
94	P5Q7N20	37.00	0.90	16.98
95	P5Q7N25	37.79	0.89	17.12
96	P5Q9N05	40.50	0.88	18.93
97	P5Q9N10	37.86	0.89	17.49
98	P5Q9N15	39.49	0.88	17.44
99	P5Q9N20	39.19	0.88	17.56
100	P5Q9N25	38.42	0.89	17.33

Tabela A.4: Índices de qualidade para treinamento da rede para previsão com horizonte de 4 dias

Experimento	Configuração	RMS(m ³ /s)	NASH	MAD
1	Q1N05	58.51	0.75	30.79
2	Q1N10	58.45	0.75	30.75
3	Q1N15	58.55	0.75	30.80
4	Q1N20	58.53	0.75	30.75
5	Q1N25	58.54	0.75	30.80
6	Q3N05	53.76	0.78	26.60
7	Q3N10	51.36	0.80	26.35
8	Q3N15	51.06	0.81	26.42
9	Q3N20	50.75	0.81	26.38
10	Q3N25	52.77	0.79	26.59
11	Q5N05	53.37	0.78	26.56
12	Q5N10	53.99	0.78	26.54
13	Q5N15	53.85	0.78	26.78
14	Q5N20	51.99	0.80	26.33
15	Q5N25	51.13	0.80	26.19
16	Q7N05	56.92	0.76	28.57
17	Q7N10	55.22	0.77	26.94
18	Q7N15	55.54	0.77	27.06

19	Q7N20	53.91	0.78	26.81
20	Q7N25	54.83	0.77	26.75
21	Q9N05	55.90	0.77	27.93
22	Q9N10	57.91	0.75	27.53
23	Q9N15	60.06	0.71	27.66
24	Q9N20	57.53	0.74	27.13
25	Q9N25	58.24	0.75	27.66
26	P1Q1N05	54.66	0.78	27.97
27	P1Q1N10	57.36	0.76	28.06
28	P1Q1N15	56.37	0.77	28.02
29	P1Q1N20	56.84	0.76	28.04
30	P1Q1N25	57.39	0.76	27.99
31	P1Q3N05	54.38	0.78	25.46
32	P1Q3N10	51.14	0.80	24.53
33	P1Q3N15	51.44	0.80	24.34
34	P1Q3N20	49.69	0.82	24.27
35	P1Q3N25	50.58	0.81	24.65
36	P1Q5N05	51.48	0.80	25.30
37	P1Q5N10	55.65	0.76	24.73
38	P1Q5N15	52.25	0.80	24.36
39	P1Q5N20	52.87	0.79	24.60
40	P1Q5N25	50.88	0.81	24.40
41	P1Q7N05	51.98	0.80	26.13
42	P1Q7N10	53.70	0.79	25.35
43	P1Q7N15	56.62	0.76	25.73
44	P1Q7N20	57.87	0.74	25.51
45	P1Q7N25	56.17	0.76	25.36
46	P1Q9N05	55.15	0.77	26.61
47	P1Q9N10	54.96	0.77	25.59
48	P1Q9N15	52.18	0.80	25.34
49	P1Q9N20	58.10	0.74	26.02
50	P1Q9N25	57.17	0.76	25.93
51	P3Q1N05	48.53	0.83	25.80
52	P3Q1N10	48.27	0.83	25.24
53	P3Q1N15	48.99	0.82	25.42
54	P3Q1N20	50.05	0.82	25.50
55	P3Q1N25	50.02	0.82	25.54
56	P3Q3N05	51.07	0.80	25.04
57	P3Q3N10	46.04	0.84	23.48
58	P3Q3N15	46.82	0.84	23.17
59	P3Q3N20	47.07	0.83	23.05
60	P3Q3N25	45.36	0.85	22.94
61	P3Q5N05	51.62	0.80	24.39
62	P3Q5N10	47.17	0.84	23.76
63	P3Q5N15	47.67	0.83	23.04
64	P3Q5N20	45.08	0.85	22.89
65	P3Q5N25	45.53	0.85	23.04
66	P3Q7N05	47.59	0.83	25.18

67	P3Q7N10	47.52	0.83	24.42
68	P3Q7N15	46.71	0.84	23.77
69	P3Q7N20	46.06	0.84	23.70
70	P3Q7N25	47.29	0.83	23.64
71	P3Q9N05	48.16	0.83	25.17
72	P3Q9N10	44.26	0.86	23.78
73	P3Q9N15	44.17	0.86	23.58
74	P3Q9N20	42.91	0.86	22.95
75	P3Q9N25	45.36	0.85	23.42
76	P5Q1N05	48.84	0.82	24.23
77	P5Q1N10	45.92	0.84	23.82
78	P5Q1N15	48.88	0.82	24.10
79	P5Q1N20	48.25	0.83	24.04
80	P5Q1N25	48.76	0.82	24.08
81	P5Q3N05	45.19	0.85	23.23
82	P5Q3N10	44.68	0.85	22.73
83	P5Q3N15	45.41	0.85	22.46
84	P5Q3N20	45.12	0.85	22.32
85	P5Q3N25	44.46	0.85	22.30
86	P5Q5N05	44.22	0.86	23.15
87	P5Q5N10	44.18	0.86	22.11
88	P5Q5N15	42.11	0.87	21.85
89	P5Q5N20	44.23	0.85	22.14
90	P5Q5N25	43.23	0.86	22.09
91	P5Q7N05	43.00	0.86	23.20
92	P5Q7N10	41.68	0.87	22.78
93	P5Q7N15	41.91	0.87	22.41
94	P5Q7N20	43.32	0.86	22.58
95	P5Q7N25	42.04	0.87	22.37
96	P5Q9N05	42.19	0.87	23.30
97	P5Q9N10	40.21	0.88	22.13
98	P5Q9N15	42.30	0.87	22.34
99	P5Q9N20	39.96	0.88	21.96
100	P5Q9N25	41.49	0.87	22.25

Tabela A.5: Índices de qualidade para treinamento da rede para previsão com horizonte de 5 dias

Experimento	Configuração	RMS(m ³ /s)	NASH	MAD
1	Q1N05	65.33	0.69	36.04
2	Q1N10	65.35	0.69	36.09
3	Q1N15	65.51	0.68	36.04
4	Q1N20	65.47	0.68	36.05
5	Q1N25	65.48	0.68	36.09
6	Q3N05	61.04	0.73	32.54
7	Q3N10	60.46	0.73	32.61
8	Q3N15	57.84	0.76	32.08
9	Q3N20	58.11	0.75	32.01
10	Q3N25	59.04	0.75	32.15

11	Q5N05	61.60	0.72	32.32
12	Q5N10	58.70	0.75	31.34
13	Q5N15	58.76	0.75	31.13
14	Q5N20	58.66	0.75	31.05
15	Q5N25	58.35	0.75	30.98
16	Q7N05	61.32	0.72	32.25
17	Q7N10	61.33	0.71	31.95
18	Q7N15	60.38	0.72	31.68
19	Q7N20	61.03	0.71	31.95
20	Q7N25	60.39	0.72	31.62
21	Q9N05	64.32	0.69	33.37
22	Q9N10	62.48	0.71	32.64
23	Q9N15	66.83	0.65	32.59
24	Q9N20	66.40	0.64	32.34
25	Q9N25	67.15	0.64	32.62
26	P1Q1N05	122.46	-2.36	98.03
27	P1Q1N10	58.20	0.75	32.32
28	P1Q1N15	58.93	0.74	32.40
29	P1Q1N20	58.75	0.75	32.39
30	P1Q1N25	58.72	0.75	32.37
31	P1Q3N05	59.33	0.74	30.67
32	P1Q3N10	59.55	0.74	30.19
33	P1Q3N15	55.81	0.77	29.57
34	P1Q3N20	58.29	0.75	29.78
35	P1Q3N25	56.91	0.76	30.02
36	P1Q5N05	56.46	0.77	30.05
37	P1Q5N10	56.32	0.77	29.71
38	P1Q5N15	55.24	0.78	28.97
39	P1Q5N20	55.37	0.78	29.14
40	P1Q5N25	55.24	0.78	29.14
41	P1Q7N05	56.71	0.76	30.74
42	P1Q7N10	57.43	0.75	30.19
43	P1Q7N15	55.63	0.77	29.82
44	P1Q7N20	57.28	0.75	29.93
45	P1Q7N25	57.56	0.75	29.75
46	P1Q9N05	57.37	0.76	30.94
47	P1Q9N10	56.86	0.76	30.13
48	P1Q9N15	58.96	0.74	30.29
49	P1Q9N20	60.53	0.72	30.38
50	P1Q9N25	59.92	0.73	30.41
51	P3Q1N05	53.00	0.79	29.90
52	P3Q1N10	55.04	0.78	29.87
53	P3Q1N15	55.05	0.78	29.76
54	P3Q1N20	54.49	0.78	29.76
55	P3Q1N25	56.60	0.76	30.10
56	P3Q3N05	51.93	0.80	28.50
57	P3Q3N10	50.93	0.81	28.11
58	P3Q3N15	51.23	0.81	28.01

59	P3Q3N20	51.38	0.81	28.05
60	P3Q3N25	52.03	0.80	28.05
61	P3Q5N05	52.62	0.80	28.80
62	P3Q5N10	50.37	0.81	27.80
63	P3Q5N15	49.97	0.82	27.74
64	P3Q5N20	50.46	0.81	27.61
65	P3Q5N25	49.80	0.82	27.48
66	P3Q7N05	52.36	0.80	29.32
67	P3Q7N10	50.03	0.81	28.07
68	P3Q7N15	49.50	0.82	27.88
69	P3Q7N20	50.82	0.81	28.13
70	P3Q7N25	49.92	0.81	27.62
71	P3Q9N05	51.32	0.81	28.90
72	P3Q9N10	51.42	0.81	28.55
73	P3Q9N15	50.04	0.82	28.27
74	P3Q9N20	50.35	0.81	28.25
75	P3Q9N25	51.92	0.80	28.48
76	P5Q1N05	50.43	0.81	28.11
77	P5Q1N10	49.89	0.82	28.04
78	P5Q1N15	50.97	0.81	28.14
79	P5Q1N20	51.12	0.81	28.25
80	P5Q1N25	51.84	0.80	28.23
81	P5Q3N05	47.79	0.83	27.11
82	P5Q3N10	47.83	0.83	26.63
83	P5Q3N15	49.23	0.82	26.89
84	P5Q3N20	49.63	0.82	26.77
85	P5Q3N25	49.08	0.82	26.66
86	P5Q5N05	48.17	0.83	27.03
87	P5Q5N10	47.36	0.84	26.50
88	P5Q5N15	47.08	0.84	26.51
89	P5Q5N20	47.07	0.84	26.52
90	P5Q5N25	47.17	0.84	26.68
91	P5Q7N05	48.03	0.83	27.49
92	P5Q7N10	47.23	0.83	26.97
93	P5Q7N15	48.34	0.83	27.01
94	P5Q7N20	46.64	0.84	26.79
95	P5Q7N25	47.96	0.83	26.69
96	P5Q9N05	49.69	0.82	28.19
97	P5Q9N10	47.55	0.83	27.10
98	P5Q9N15	47.66	0.83	27.02
99	P5Q9N20	48.10	0.83	27.07
100	P5Q9N25	50.50	0.81	27.29

Tabela A.6: Índices de qualidade para treinamento da rede para previsão com horizonte de 6 dias

Experimento	Configuração	RMS(m ³ /s)	NASH	MAD
1	Q1N05	71.61	0.63	40.95
2	Q1N10	71.76	0.62	41.05

3	Q1N15	71.74	0.62	40.96
4	Q1N20	71.73	0.62	40.90
5	Q1N25	71.84	0.62	40.92
6	Q3N05	66.52	0.68	38.26
7	Q3N10	64.83	0.69	37.15
8	Q3N15	65.49	0.69	37.49
9	Q3N20	65.82	0.68	37.86
10	Q3N25	65.24	0.69	37.03
11	Q5N05	66.68	0.67	37.73
12	Q5N10	66.46	0.68	37.45
13	Q5N15	67.04	0.67	37.44
14	Q5N20	67.00	0.67	37.39
15	Q5N25	65.56	0.69	37.15
16	Q7N05	67.58	0.67	39.18
17	Q7N10	69.94	0.64	39.07
18	Q7N15	68.66	0.65	39.07
19	Q7N20	66.95	0.67	38.47
20	Q7N25	67.68	0.66	38.95
21	Q9N05	69.97	0.64	37.32
22	Q9N10	70.46	0.63	37.17
23	Q9N15	68.14	0.66	36.71
24	Q9N20	67.09	0.67	36.80
25	Q9N25	68.96	0.65	36.90
26	P1Q1N05	64.77	0.69	37.24
27	P1Q1N10	64.62	0.70	37.16
28	P1Q1N15	64.22	0.70	37.13
29	P1Q1N20	64.38	0.70	37.02
30	P1Q1N25	64.51	0.70	37.07
31	P1Q3N05	61.98	0.72	35.15
32	P1Q3N10	62.27	0.72	34.96
33	P1Q3N15	61.31	0.72	34.16
34	P1Q3N20	61.04	0.73	33.99
35	P1Q3N25	65.69	0.67	34.60
36	P1Q5N05	62.02	0.72	35.74
37	P1Q5N10	62.43	0.71	35.08
38	P1Q5N15	63.81	0.70	35.08
39	P1Q5N20	60.95	0.73	34.70
40	P1Q5N25	60.11	0.73	34.46
41	P1Q7N05	62.09	0.72	35.75
42	P1Q7N10	61.19	0.73	35.54
43	P1Q7N15	62.92	0.71	35.82
44	P1Q7N20	65.68	0.67	35.66
45	P1Q7N25	62.37	0.71	35.35
46	P1Q9N05	64.46	0.70	35.38
47	P1Q9N10	62.77	0.71	34.87
48	P1Q9N15	64.62	0.69	34.80
49	P1Q9N20	64.88	0.69	34.77
50	P1Q9N25	62.07	0.72	34.20

51	P3Q1N05	59.43	0.74	34.63
52	P3Q1N10	59.73	0.74	34.62
53	P3Q1N15	60.37	0.73	34.87
54	P3Q1N20	60.97	0.73	34.96
55	P3Q1N25	60.53	0.73	35.17
56	P3Q3N05	58.13	0.75	33.77
57	P3Q3N10	58.55	0.75	33.17
58	P3Q3N15	58.64	0.75	33.14
59	P3Q3N20	59.03	0.74	33.57
60	P3Q3N25	60.17	0.73	33.73
61	P3Q5N05	58.42	0.75	33.34
62	P3Q5N10	57.30	0.76	33.24
63	P3Q5N15	58.33	0.75	33.14
64	P3Q5N20	58.31	0.75	33.08
65	P3Q5N25	57.32	0.76	33.10
66	P3Q7N05	57.20	0.76	33.81
67	P3Q7N10	55.90	0.77	33.01
68	P3Q7N15	56.24	0.77	33.15
69	P3Q7N20	56.15	0.77	33.08
70	P3Q7N25	56.09	0.77	33.02
71	P3Q9N05	57.21	0.76	33.03
72	P3Q9N10	56.97	0.76	32.63
73	P3Q9N15	57.35	0.76	32.63
74	P3Q9N20	57.26	0.76	32.62
75	P3Q9N25	57.51	0.76	32.62
76	P5Q1N05	56.42	0.77	32.75
77	P5Q1N10	57.76	0.76	33.13
78	P5Q1N15	57.66	0.76	33.00
79	P5Q1N20	58.44	0.75	33.26
80	P5Q1N25	58.36	0.75	33.26
81	P5Q3N05	56.30	0.77	32.44
82	P5Q3N10	55.24	0.78	31.79
83	P5Q3N15	55.85	0.77	32.12
84	P5Q3N20	55.23	0.78	31.91
85	P5Q3N25	56.27	0.77	32.04
86	P5Q5N05	55.78	0.77	32.51
87	P5Q5N10	55.96	0.77	31.89
88	P5Q5N15	55.24	0.77	31.74
89	P5Q5N20	55.02	0.78	31.71
90	P5Q5N25	55.30	0.77	31.84
91	P5Q7N05	54.12	0.79	32.09
92	P5Q7N10	54.32	0.78	31.85
93	P5Q7N15	54.26	0.78	31.83
94	P5Q7N20	53.94	0.79	31.69
95	P5Q7N25	54.53	0.78	31.63
96	P5Q9N05	55.70	0.77	31.94
97	P5Q9N10	54.56	0.78	31.18
98	P5Q9N15	55.04	0.78	31.39

99	P5Q9N20	54.89	0.78	31.26
100	P5Q9N25	55.28	0.77	31.22

Tabela A.7: Índices de qualidade para treinamento da rede para previsão com horizonte de 7 dias

Experimento	Configuração	RMS(m ³ /s)	NASH	MAD
1	Q1N05	77.68	0.56	45.30
2	Q1N10	77.77	0.56	45.30
3	Q1N15	77.73	0.56	45.27
4	Q1N20	77.98	0.56	45.35
5	Q1N25	77.85	0.56	45.37
6	Q3N05	72.06	0.62	41.47
7	Q3N10	70.78	0.63	40.69
8	Q3N15	71.13	0.63	40.73
9	Q3N20	70.99	0.63	40.77
10	Q3N25	70.88	0.63	40.74
11	Q5N05	74.42	0.60	42.86
12	Q5N10	72.08	0.62	41.13
13	Q5N15	72.05	0.62	41.48
14	Q5N20	71.62	0.63	41.00
15	Q5N25	71.02	0.63	40.89
16	Q7N05	74.02	0.60	42.63
17	Q7N10	73.60	0.60	41.85
18	Q7N15	74.73	0.59	42.28
19	Q7N20	75.82	0.58	42.31
20	Q7N25	72.87	0.61	41.36
21	Q9N05	74.94	0.59	42.80
22	Q9N10	75.08	0.59	42.16
23	Q9N15	76.63	0.57	42.42
24	Q9N20	75.35	0.58	42.55
25	Q9N25	75.11	0.59	41.81
26	P1Q1N05	70.45	0.64	41.19
27	P1Q1N10	70.39	0.64	41.16
28	P1Q1N15	70.03	0.64	41.21
29	P1Q1N20	70.49	0.64	41.11
30	P1Q1N25	70.53	0.64	41.29
31	P1Q3N05	68.58	0.66	39.59
32	P1Q3N10	67.88	0.66	39.04
33	P1Q3N15	67.23	0.67	38.73
34	P1Q3N20	66.87	0.67	38.61
35	P1Q3N25	70.47	0.63	39.07
36	P1Q5N05	68.21	0.66	39.58
37	P1Q5N10	67.88	0.66	39.39
38	P1Q5N15	67.96	0.66	39.53
39	P1Q5N20	68.80	0.65	39.53
40	P1Q5N25	69.22	0.65	39.71
41	P1Q7N05	67.91	0.66	39.76
42	P1Q7N10	67.74	0.66	39.29

43	P1Q7N15	68.98	0.65	39.47
44	P1Q7N20	69.62	0.64	39.44
45	P1Q7N25	67.81	0.66	39.28
46	P1Q9N05	68.86	0.65	39.73
47	P1Q9N10	70.33	0.64	39.89
48	P1Q9N15	68.79	0.65	39.62
49	P1Q9N20	68.71	0.65	39.28
50	P1Q9N25	70.39	0.64	39.65
51	P3Q1N05	65.45	0.69	38.62
52	P3Q1N10	65.88	0.68	38.83
53	P3Q1N15	66.32	0.68	38.77
54	P3Q1N20	65.92	0.68	38.72
55	P3Q1N25	66.31	0.68	38.98
56	P3Q3N05	64.89	0.69	37.96
57	P3Q3N10	64.75	0.69	37.31
58	P3Q3N15	63.90	0.70	37.14
59	P3Q3N20	63.44	0.71	37.23
60	P3Q3N25	64.68	0.69	37.21
61	P3Q5N05	64.06	0.70	37.02
62	P3Q5N10	66.43	0.67	37.23
63	P3Q5N15	63.98	0.70	37.10
64	P3Q5N20	64.01	0.70	37.01
65	P3Q5N25	64.33	0.70	36.92
66	P3Q7N05	64.28	0.70	37.60
67	P3Q7N10	63.52	0.71	37.16
68	P3Q7N15	63.29	0.71	37.24
69	P3Q7N20	63.30	0.71	37.01
70	P3Q7N25	64.22	0.70	37.44
71	P3Q9N05	64.10	0.70	37.76
72	P3Q9N10	63.27	0.71	37.47
73	P3Q9N15	63.99	0.70	37.46
74	P3Q9N20	63.61	0.70	37.22
75	P3Q9N25	63.61	0.70	37.16
76	P5Q1N05	62.67	0.71	36.54
77	P5Q1N10	63.62	0.70	36.79
78	P5Q1N15	63.51	0.70	36.83
79	P5Q1N20	64.95	0.69	37.13
80	P5Q1N25	65.10	0.69	37.28
81	P5Q3N05	62.16	0.72	35.92
82	P5Q3N10	62.04	0.72	35.82
83	P5Q3N15	62.74	0.71	35.81
84	P5Q3N20	62.27	0.72	35.93
85	P5Q3N25	62.74	0.71	35.95
86	P5Q5N05	62.84	0.71	36.35
87	P5Q5N10	62.09	0.72	35.91
88	P5Q5N15	63.05	0.71	35.82
89	P5Q5N20	61.66	0.72	35.66
90	P5Q5N25	62.52	0.71	35.97

91	P5Q7N05	61.72	0.72	36.15
92	P5Q7N10	61.26	0.73	35.97
93	P5Q7N15	61.00	0.73	35.85
94	P5Q7N20	61.35	0.72	35.93
95	P5Q7N25	61.59	0.72	36.00
96	P5Q9N05	62.20	0.72	36.48
97	P5Q9N10	60.93	0.73	36.16
98	P5Q9N15	61.57	0.72	36.17
99	P5Q9N20	61.28	0.72	35.79
100	P5Q9N25	61.43	0.72	36.03

APÊNDICE B

Este capítulo apresenta os gráficos do conjunto de erro de treinamento relativos as melhores configurações de treinamento

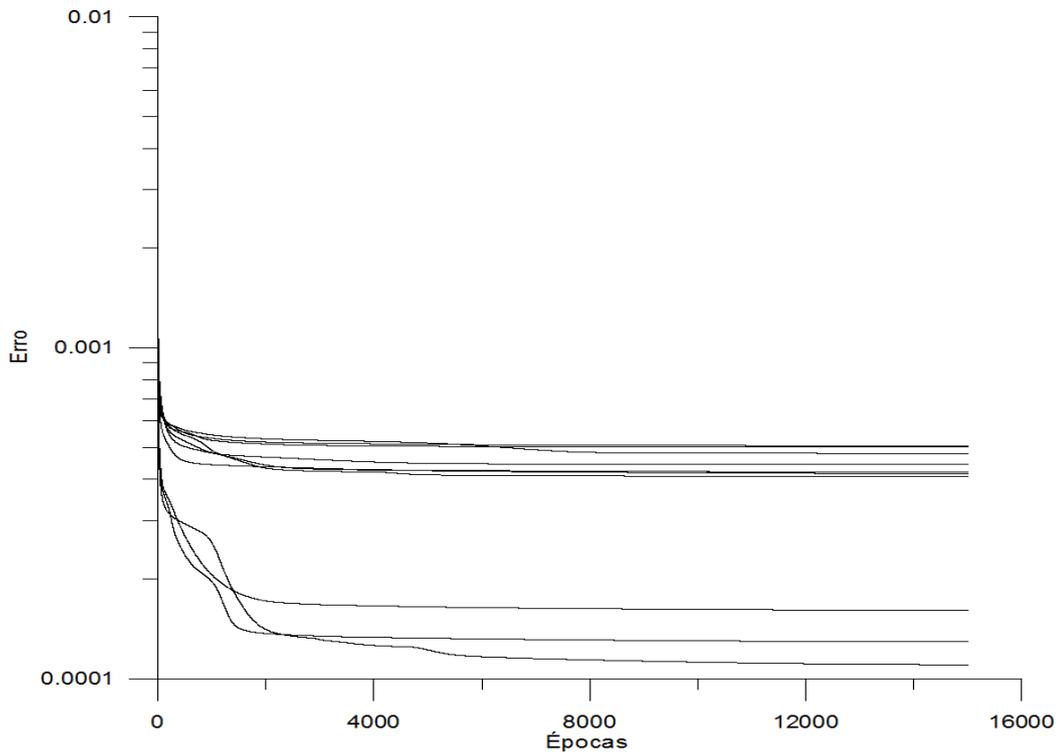


Figura B.1: Erro do conjunto de treinamento do experimento Q3N20 para previsão com horizonte de 1 dia

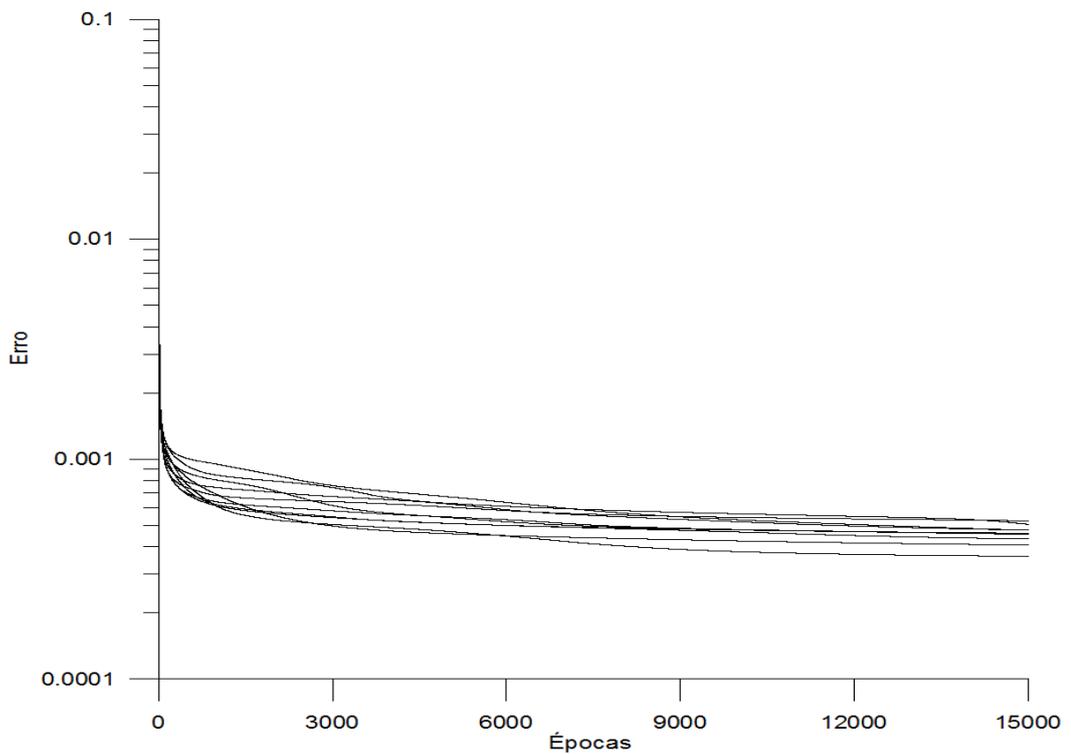


Figura B.2: Erro do conjunto de treinamento do experimento P5Q7N10 para previsão com horizonte de 2 dias

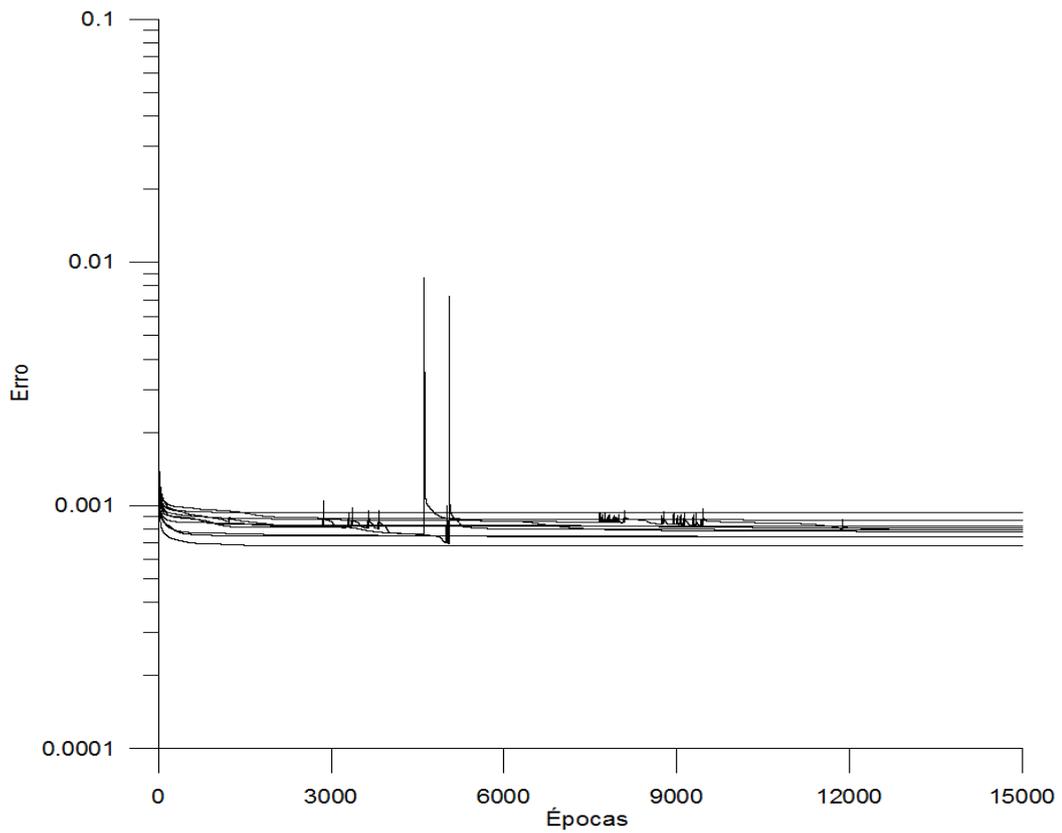


Figura B.3: Erro do conjunto de treinamento do experimento Q3N25 para previsão com horizonte de 2 dias

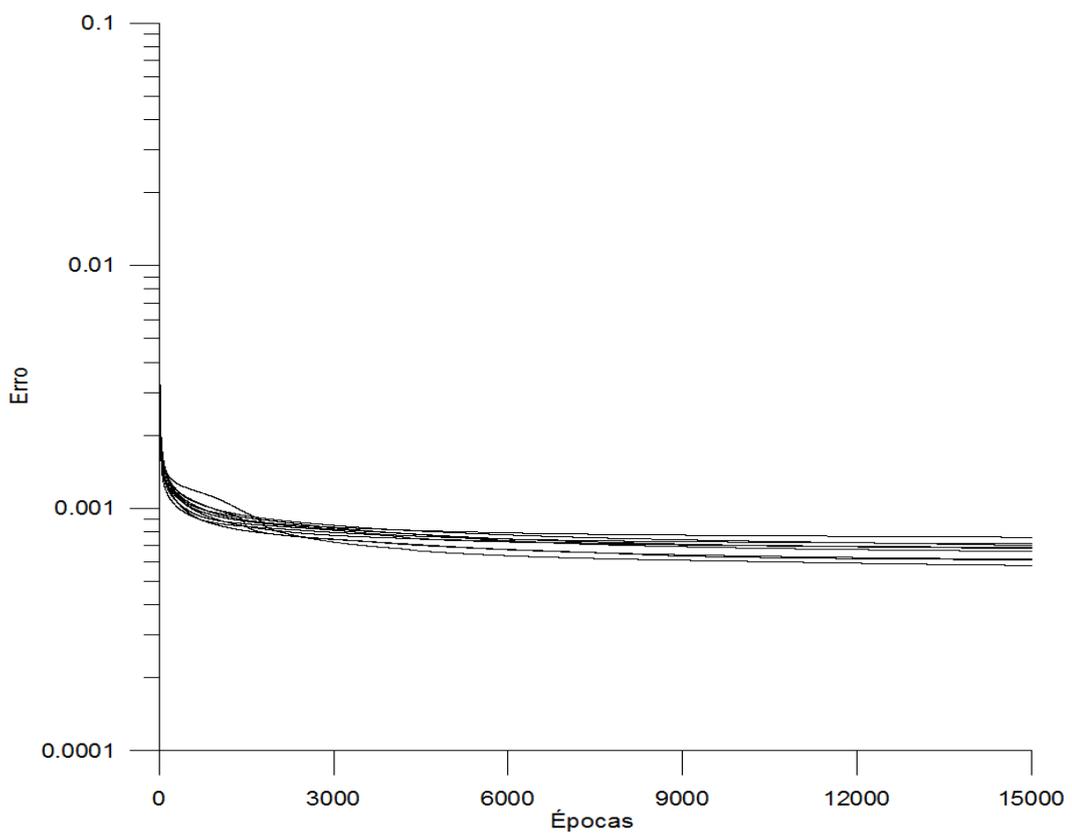


Figura B.4: Erro do conjunto de treinamento do experimento P5Q7N20 para previsão com horizonte de 3 dias

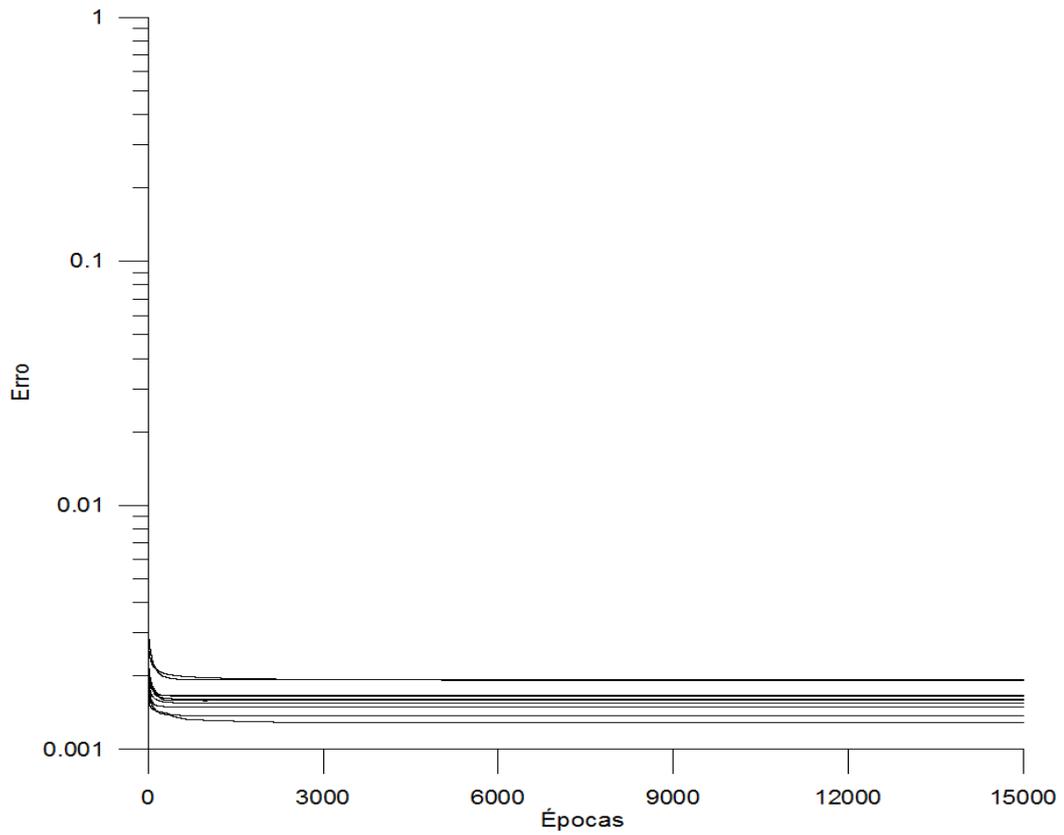


Figura B.5: Erro do conjunto de treinamento do experimento Q3N5 para previsão com horizonte de 3 dias

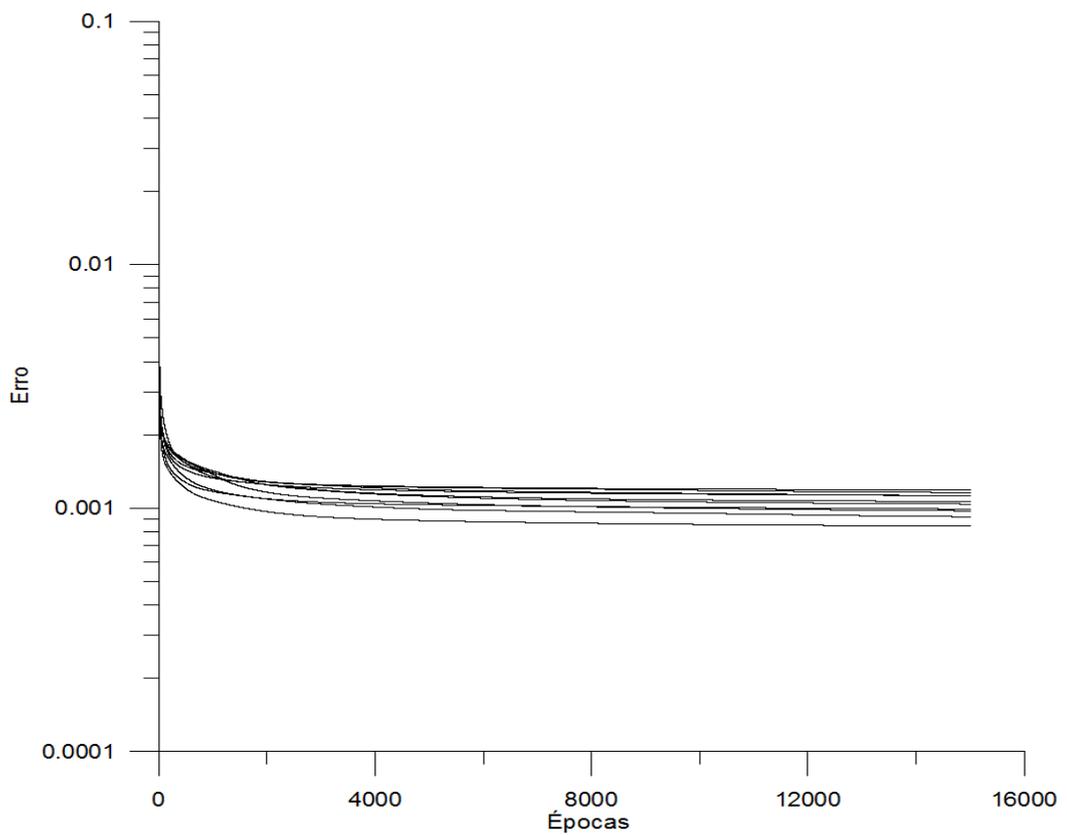


Figura B.6: Erro do conjunto de treinamento do experimento P5Q9N20 para previsão com horizonte de 4 dias

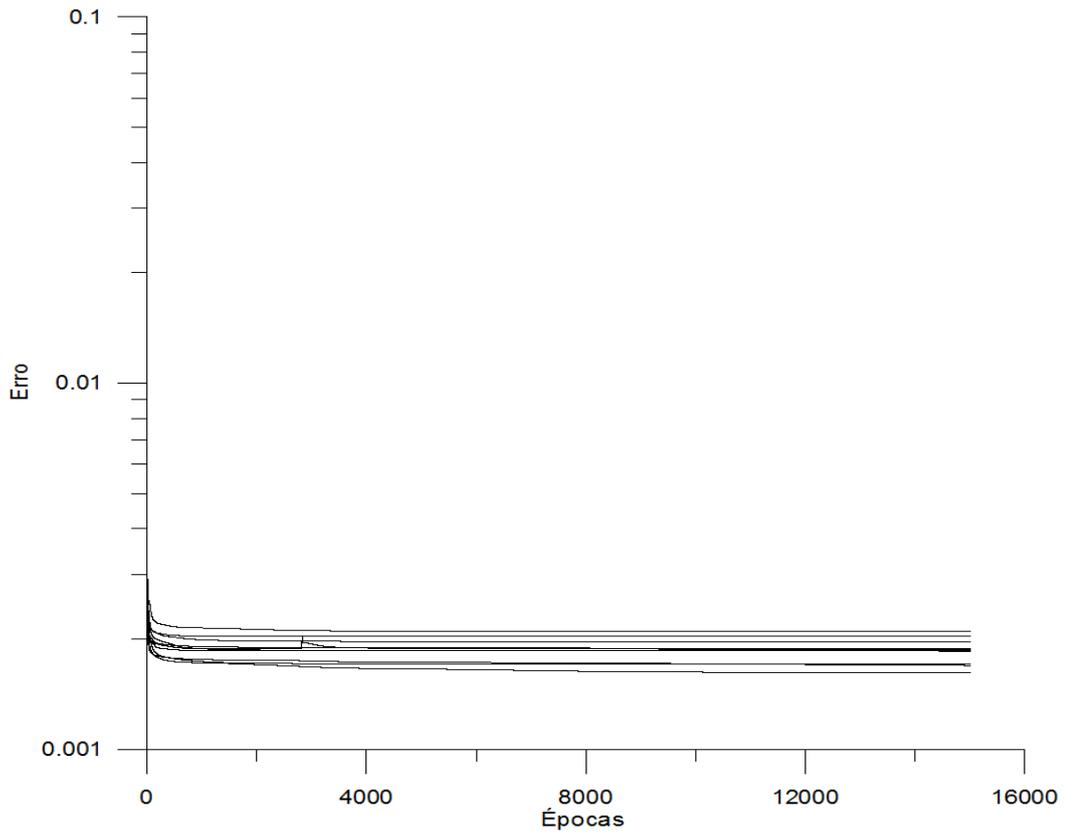


Figura B.7: Erro do conjunto de treinamento do experimento Q3N20 para previsão com horizonte de 4 dias

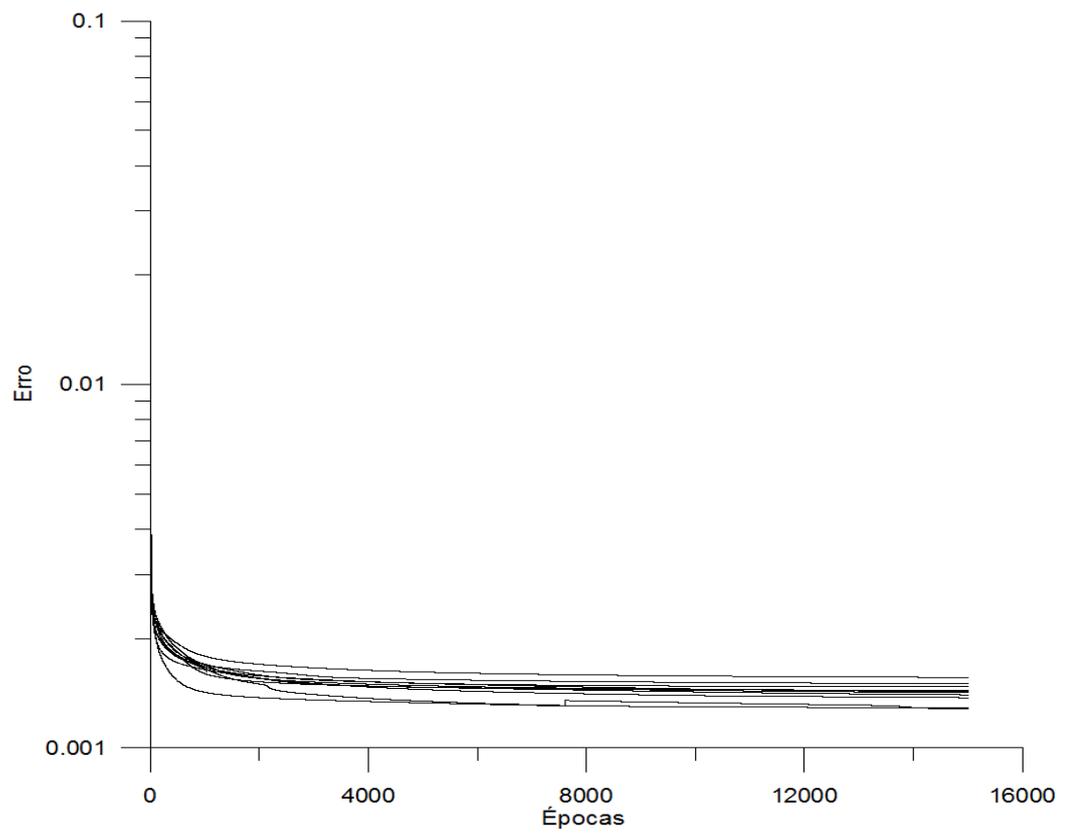


Figura B.8: Erro do conjunto de treinamento do experimento P5Q7N20 para previsão com horizonte de 5 dias

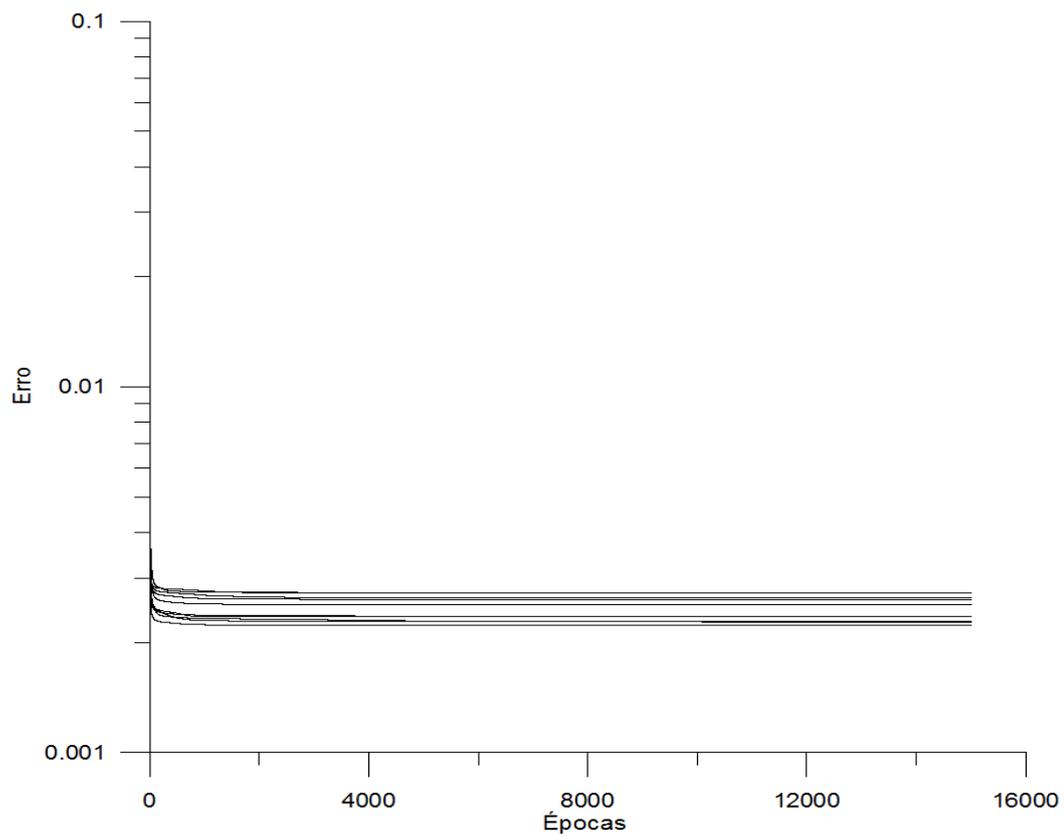


Figura B.9: Erro do conjunto de treinamento do experimento Q3N15 para previsão com horizonte de 5 dias

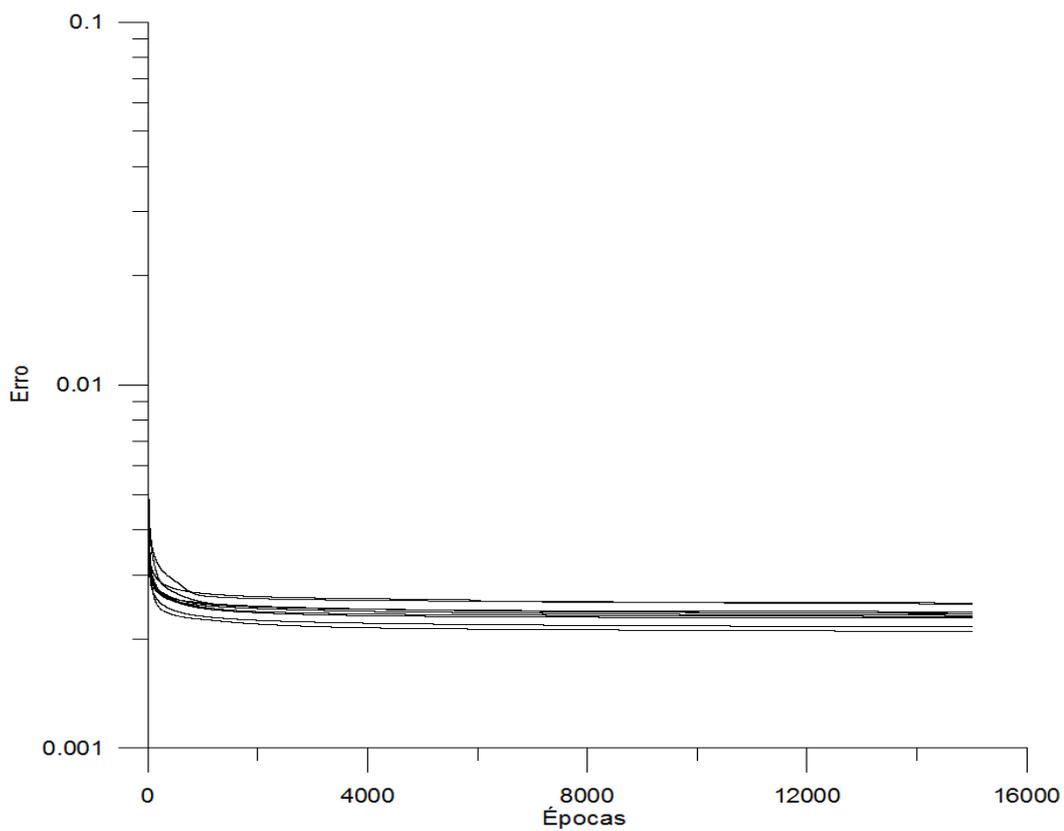


Figura B.10: Erro do conjunto de treinamento do experimento P5Q7N5 para previsão com horizonte de 6 dias

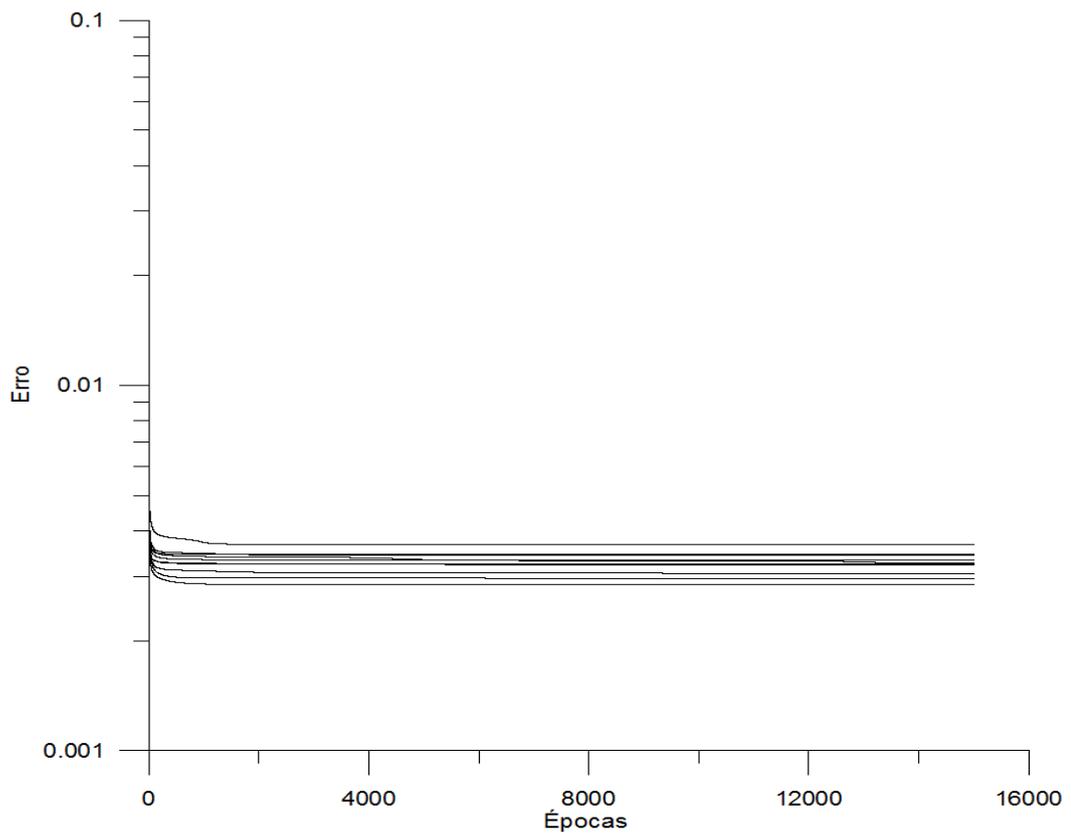


Figura B.11: Erro do conjunto de treinamento do experimento Q3N10 para previsão com horizonte de 6 dias

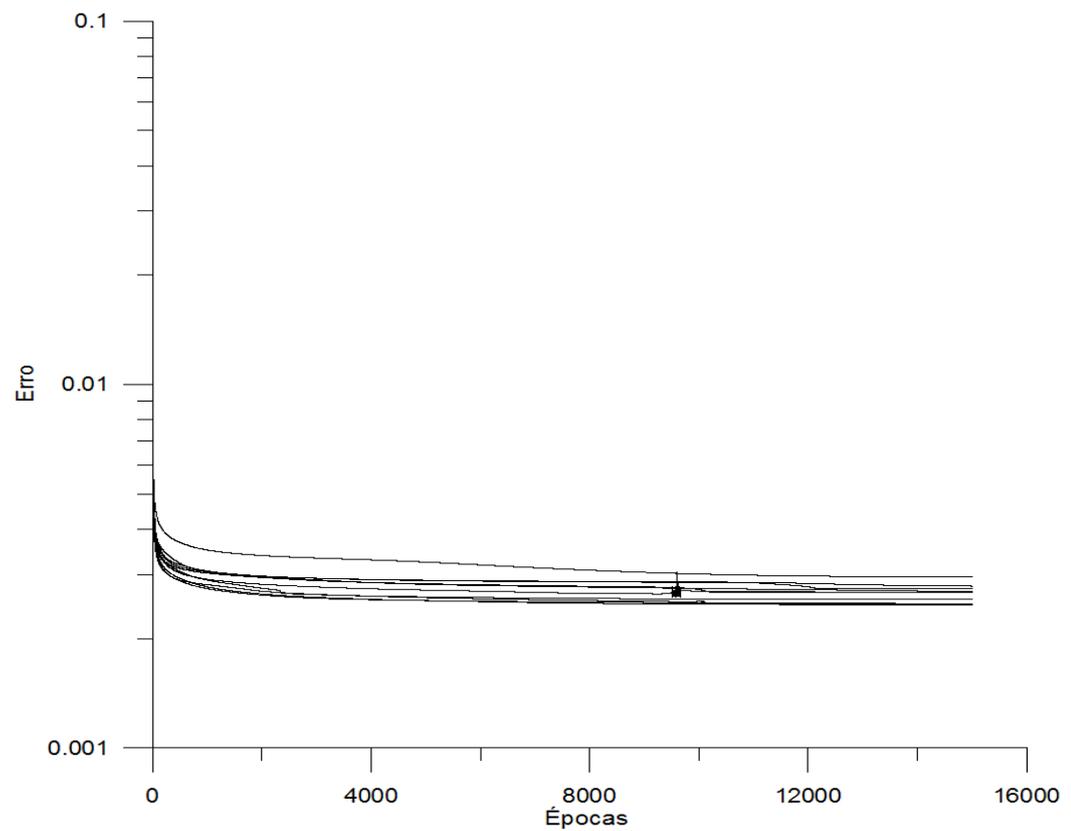


Figura B.12: Erro do conjunto de treinamento do experimento P5Q9N10 para previsão com horizonte de 7 dias

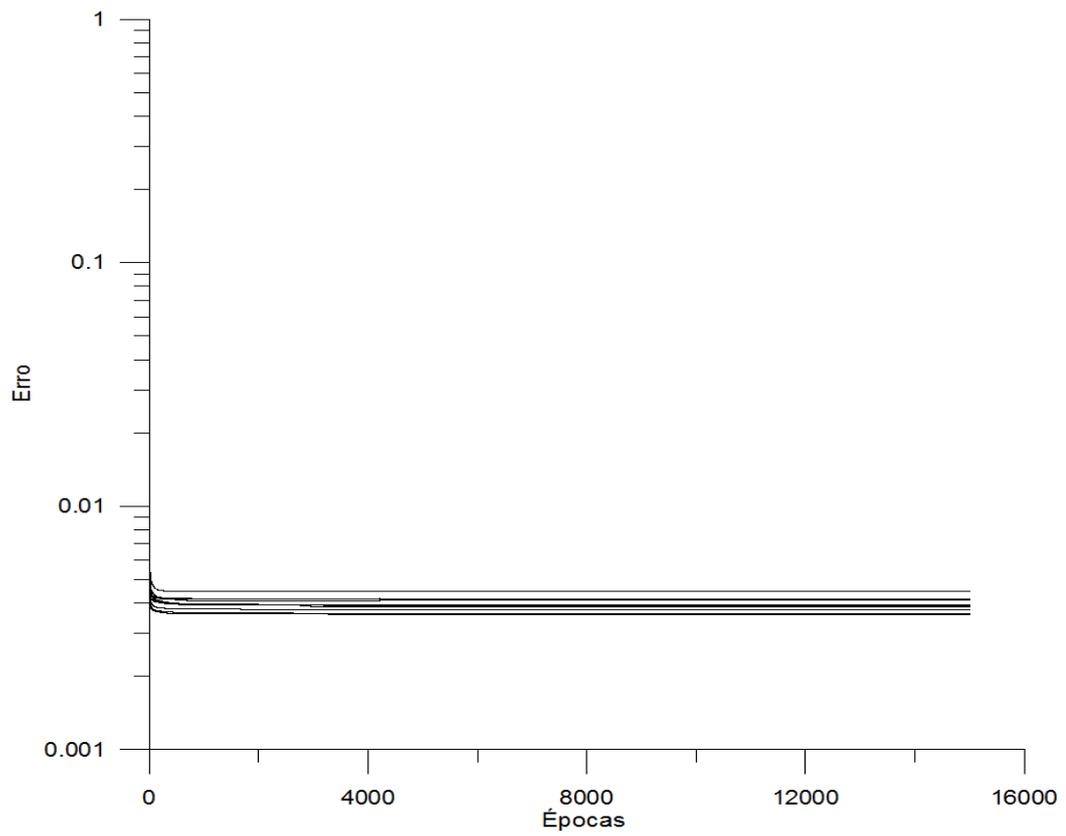


Figura B.13: Erro do conjunto de treinamento do experimento Q3N10 para previsão com horizonte de 7 dias