

UNIVERSIDADE FEDERAL FLUMINENSE

ESCOLA DE ENGENHARIA

PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE  
TELECOMUNICAÇÕES

GUILHERME FABRIS FLORES

OTIMIZAÇÃO NATURAL E REDES NEURAS ARTIFICIAIS PARA PROGRAMAÇÃO  
DIÁRIA DE PEQUENAS CENTRAIS HIDRELÉTRICAS

NITERÓI, RJ

2018

GUILHERME FABRIS FLORES  
MATRÍCULA: M054.213.011

OTIMIZAÇÃO NATURAL E REDES NEURAS ARTIFICIAIS PARA PROGRAMAÇÃO  
DIÁRIA DE PEQUENAS CENTRAIS HIDRELÉTRICAS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense, como requisito parcial para obtenção do Grau de Mestre em Engenharia Elétrica e de Telecomunicações.

Área de concentração: Sistemas de Energia Elétrica.

Orientador: Prof. Vitor Hugo Ferreira, D. Sc.

Niterói, RJ

2018

## Ficha catalográfica automática - SDC/BEE

F634o Flores, Guilherme Fabris  
Otimização Natural e Redes Neurais Artificiais Para  
Programação Diária de Pequenas Centrais Hidrelétricas /  
Guilherme Fabris Flores ; Vitor Hugo Ferreira, orientador.  
Niterói, 2018.  
99 p. : il.

Dissertação (mestrado)-Universidade Federal Fluminense,  
Niterói, 2018.

DOI: <http://dx.doi.org/10.22409/PPCERT.2018.m.09854228746>

1. Ceração hídrica. 2. Previsão de comportamento  
linimétrico. 3. Redes Neurais Artificiais. 4. Otimização  
por Enxame de Partículas. 5. Produção intelectual. I.  
Título II. Ferreira, Vitor Hugo, orientador. III. Universidade  
Federal Fluminense. Escola de Engenharia.

CDD -

GUILHERME FABRIS FLORES

OTIMIZAÇÃO NATURAL E REDES NEURAS ARTIFICIAIS PARA PROGRAMAÇÃO  
DIÁRIA DE PEQUENAS CENTRAIS HIDRELÉTRICAS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense, como requisito parcial para obtenção do Grau de Mestre em Engenharia Elétrica e de Telecomunicações.

Área de concentração: Sistemas de Energia Elétrica.

Aprovado em \_\_\_/\_\_\_/\_\_\_.

BANCA EXAMINADORA

---

Prof. Vitor Hugo Ferreira, D.Sc.  
Universidade Federal Fluminense

---

Prof. Márcio Zamboti Fortes, D.Sc.  
Universidade Federal Fluminense

---

Prof. Djalma Mosqueira Falcão, Ph.D.  
Universidade Federal do Rio de Janeiro

Niterói, RJ

2018

Dedico este trabalho a meu filho, nascido no meio desta etapa de minha vida, e que, com o brilho de seus olhos, trouxe toda uma nova forma de observar e entender o mundo e a vida.

## AGRADECIMENTOS

Agradeço a minha esposa, por me permitir a felicidade de sua companhia, por ser minha balança, minha confidente e meu equilíbrio.

Agradeço à minha família pelos valores que me passaram, por toda a minha educação e por terem sido o porto, o caminho e o apoio de todas as decisões que trilhei

Em especial, agradeço ao meu orientador e professor Vitor Hugo Ferreira, por todos os seus ensinamentos e orientações neste processo acadêmico e por acreditar no meu potencial.

Agradeço também ao professor Marcio Zamboti Fortes, por ser uma força impar no meio acadêmico, com ensinamentos que vão além das paredes da universidade.

“Nossa existência é transitória como as nuvens do outono. Observar o nascimento e a morte dos seres é como olhar os momentos da dança. A duração da vida é como o brilho de um relâmpago no céu, tal como uma torrente que se precipita montanha abaixo.”

Sidarta Gautama - Buda

## RESUMO

O parque hidrelétrico brasileiro representa aproximadamente 63,96% da potência total instalada para produção de energia elétrica no país, caracterizando a dependência direta da geração com o regime hídrico. A hidroenergia disponível para um determinado período futuro é incerta e depende fortemente do armazenamento atual dos reservatórios, das vazões afluentes futuras e das precipitações de montante. O uso ineficaz da água na operação do sistema de reservatórios implica em custos adicionais de geração térmica complementar, em desperdícios de água por vertimentos desnecessários e pela operação das centrais hidrelétricas fora das faixas de maior eficiência. Na intenção de minimizar o custo esperado de produção energética para certo horizonte temporal, de suprir a demanda e de minimizar perdas via vertimentos, é importante prever a disponibilidade hídrica do reservatório em diferentes escalas temporais. A determinação da operação ótima e segura de sistemas complexos como o de uma hidrelétrica consiste na definição de um conjunto de controles que maximizam um determinado critério de despacho, garantindo simultaneamente a operação dos reservatórios dentro dos seus limites operativos. Este estudo objetiva analisar o planejamento ótimo de curto prazo de centrais hidrelétricas com pequena capacidade de regulação hidrológica, utilizando a técnica de Redes Neurais Artificiais em conjunto com o método de Otimização por Enxame de Partículas. Para isso foi desenvolvido um modelo baseado em Redes Neurais Artificiais para previsão do comportamento do nível do reservatório de barragens no horizonte de 24 (vinte e quatro) horas à frente, que é utilizado como dado de entrada da metodologia de Otimização por Enxame de Partículas para determinação do despacho otimizado que respeite, caso possível, as condições de contorno de nível.

**Palavras-chave:** Geração hídrica, Previsão de comportamento limnimétrico<sup>1</sup> utilizando Redes Neurais Artificiais e Otimização de despacho diário por Otimização por Enxame de Partículas.

---

<sup>1</sup> Limnimétrico: Levantamento de dados do nível d água.

## ABSTRACT

The Brazilian hydroelectric park accounts for approximately 63.96% of the total installed power for electricity production in the country, characterizing the direct dependence of generation with the water regime. The hydropower available for a given future period is uncertain and depends heavily on the current storage of reservoirs, future inflows and upstream precipitation. The inefficient use of water in the operation of the reservoir system implies additional costs of complementary thermal generation, waste of water by unnecessary slopes, and the operation of hydroelectric plants outside the more efficient ranges. In order to minimize the expected cost of energy production for a certain time horizon, to meet the demand and to minimize leakage via slopes, it is important to predict the water availability of the reservoir at different time scales. The determination of the optimal and safe operation of complex systems such as that of a hydroelectric plant should consist in the definition of a set of controls that maximize a certain criterion of dispatch while ensuring the operation of the reservoirs within their operational limits. This study aims to analyze the short-term optimum planning of hydroelectric plants with little or no hydrological regulation capacity, using the technique of Artificial Neural Networks in conjunction with the Particle Swarm optimization method. For this, it was developed a model based on artificial neural networks to predict the behavior of the dam reservoir level for a horizon of 24 (twenty-four) hours ahead that is used as input data of the methodology of Optimization by Particle Swarm to determine the optimized dispatch that respects, if possible, the defined boundary conditions.

**Keywords:** Hydric generation, Prediction of limnimetric behavior using Artificial Neural Networks and Optimization of daily dispatch by Particle Swarm Optimization.

## SUMÁRIO

1.	Introdução.....	1
1.1.	Motivação .....	1
1.2.	Objetivo .....	6
1.3.	Estrutura do documento .....	7
2.	Métodos para programação diária de Pequena Centrais Hidrelétricas.....	9
2.1.	Sistemas de previsão hidrológica.....	9
2.2.	Métodos Para Operação de Reservatórios .....	14
3.	Referencial Teórico .....	17
3.1.	Modelagem de sistemas hídricos .....	17
3.2.	Redes Neurais Artificiais .....	21
3.2.1.	Algoritmo <i>Levenberg-Marquardt</i> .....	33
3.2.2.	Algoritmo de Treinamento Bayesiano.....	34
3.2.3.	Precauções para uma RNA do tipo MLP.....	38
	3.2.3.1. Arquitetura .....	38
	3.2.3.2. Número de épocas .....	39
	3.2.3.3. Inicialização dos pesos.....	40
	3.2.3.4. Normalização .....	41
3.3.	Particle swarm optimization .....	41
3.3.1.	CrITÉrios de Parada.....	45
4.	Materiais e métodos .....	47
4.1.	Sistema de Previsão .....	47
4.1.1.	Base de informações .....	47
4.1.1.	Treinamento da RNA.....	51
4.1.2.	Simulações realizadas .....	54
	4.1.2.1. Experimento 1 .....	54
	4.1.2.2. Experimento 2 .....	55

4.1.3.	Resultados do Sistema de Previsão.....	57
4.2.	Metodologia para Apoio ao Planejamento do Despacho diário de Pequenas Centrais Hidrelétricas .....	59
4.2.1.	Cenário flat .....	61
4.2.2.	Cenário otimizado.....	62
4.2.3.	Resultados do sistema para auxílio no planejamento do despacho diário de pequenas centrais hidrelétricas.....	65
5.	Conclusões .....	73
5.1.	Recomendações para trabalhos futuros.....	75
6.	Referências Bibliográficas .....	77

## LISTA DE ILUSTRAÇÕES

Figura 3.1 – Esquema básico ciclo hidrológico. (Adaptado de [17]) .....	18
Figura 3.2 – Esquema básico do neurônio artificial. (Adaptado de [49]).....	23
Figura 3.3 –Funções de Transferência. (Adaptado de [85]) .....	25
Figura 3.4 –Aprendizado supervisionado. (Adaptado de [49]) .....	27
Figura 3.5 – RNA do tipo <i>Perceptron</i> . (Adaptado de [49]) .....	28
Figura 3.6 – Representação gráfica de um problema de otimização. (Adaptado de [49]) .....	30
Figura 3.7 – Representação gráfica de um problema de otimização. (Adaptado de [88]) .....	39
Figura 4.1 – Fluxo de funcionamento do sistema desenvolvido. ....	48
Figura 4.2 – Geolocalização das estações meteorológicas a montante do reservatório. .....	49
Figura 4.3 – Análise da correlação existe entre a chuva observada a montante e o comportamento limnimético do reservatório.....	52
Figura 4.4 – Representação gráfica da separação das bases para treinamento da RNA .....	52
Figura 4.5 – Representação gráfica das previsões obtidas no experimento 1 .....	55
Figura 4.6 – Representação gráfica das previsões obtidas no experimento 2 .....	56
Figura 4.7 – Curvas-guias da central estudada .....	60
Figura 4.8 – Exemplo do método de otimização por Enxame de Partículas .....	64
Figura 4.9 – Resposta do método para a entrada real de despacho .....	66
Figura 4.10 – Resposta do método para a entrada máxima de despacho .....	66
Figura 4.11 – Previsão do método para despacho <i>flat</i> .....	67
Figura 4.12 – Previsão do método para despacho otimizado por PSO.....	68
Figura 4.13 – Previsão do método para despacho otimizado por PSO.....	69
Figura 4.14 – Exemplo de resposta gerada pelo método, simulação 2.....	72
Figura 4.15 – Exemplo de resposta gerada pelo método, simulação 4.....	72

## LISTA DE TABELAS

Tabela 4-1 – Previsões obtidas utilizando RNAs para o período chuvoso .....	57
Tabela 4-2 – Previsões obtidas utilizando RNAs para o período de transição chuvoso x seco .....	58
Tabela 4-3 – Previsões obtidas utilizando RNAs para o período seco .....	58
Tabela 4-4 – Previsões obtidas utilizando RNAs para o período de transição seco x chuvoso .....	58
Tabela 4-5 – Média dos EAPM's obtidos nas previsões .....	59
Tabela 4-6 – Resumo dos EAPM's obtidos nas previsões .....	59
Tabela 4-7 – Valores horários de despacho para a simulação analisada .....	70
Tabela 4-8 – Resultado dos cenários gerador pelo método para Auxílio no Planejamento de despacho de PCH's .....	71

## LISTA DE ABREVIATURAS, SIGLAS E SÍMBOLOS

ONS	Operador Nacional do Sistema Interligado
MLT	Média de Longo Termo
PMO	Programa Mensal de Operação
SIN	Sistema Interligado Nacional
RNA	Rede Neural Artificial
PCH	Pequena Central Hidrelétrica
MLP	Multi-layer Perceptron
PSO	Otimização por Enxame de Partículas
EUA	Estados Unidos da América
SLM	Modelo Linear Simples
LPM	Modelo de Perturbação Linear
NNLPM	Modelo de Perturbação Linear do Vizinho Mais Próximo
SMAP	Soil Moisture Accounting Procedure
UHE	Usina Hidroelétrica
NSRBN	Non-linear Sigmoidal Regression Blocks Networks
CEPEL	Centro de Pesquisas de Energia Elétrica
PREVIVAZH	Modelo de Previsão de Vazões Diárias
PREVIVAZ	Modelo de Previsão de Vazões Semanais
AR	Modelo Autorregressivos Sem Média Móvel
ARMA	Modelo Autorregressivos Com Média Móvel

PREVIVAZM	Modelo de Previsão de Vazões Mensais
RBF	Função de Base Radial
ARD	Algoritmo de Determinação Automática de Relevância
RMSE	Raiz do Erro Quadrático Médio
MANM	Metros Acima do Nível do Mar
CEMADEN-RJ do Rio de Janeiro	Centro Estadual de Monitoramento e Alerta de Desastres Naturais
ANA	Agência Nacional de Águas
EAPM	Erro Absoluto Percentual Médio
MAPE	Erro Absoluto Percentual Médio

## 1. INTRODUÇÃO

### *1.1. MOTIVAÇÃO*

O parque hidrelétrico brasileiro representa aproximadamente 63,96% da potência total instalada para produção de energia elétrica no país [1] caracterizando a dependência direta da geração com o regime hídrico. Além disso, a existência de potenciais hídricos ainda economicamente viáveis determina a participação majoritária das hidrelétricas no atendimento à demanda energética.

A hidroenergia disponível para um determinado período futuro é incerta e depende fortemente do armazenamento atual dos reservatórios, das vazões afluentes futuras, das precipitações de montante, dentre outras variáveis. Sabe-se que o uso ineficaz da água na operação do sistema de reservatórios implica em custos adicionais de geração térmica complementar, em desperdícios de água por vertimentos desnecessários e pela operação das centrais hidrelétricas fora das faixas de maior eficiência.

Na intenção de minimizar o custo esperado de produção energética para certo horizonte temporal, de suprir a demanda e de minimizar perdas via vertimentos, o Operador Nacional do Sistema Interligado – ONS – busca estimar a disponibilidade hídrica em cada reservatório a partir de previsões de afluência em diversas escalas temporais, que servirão de base para a definição das regras operacionais ótimas de cada reservatório [2] e [3]. Os modelos de previsão adotados pelo ONS operam estrategicamente em três escalas temporais: longo, médio e curto prazo.

As previsões de vazões de longo prazo, cujos horizontes variam de alguns meses até trinta anos à frente segundo a literatura, utilizam como dados de entrada as vazões naturais médias mensais e realizam estimativas através de diferentes técnicas de modelagem, como a metodologia de Redes Neurais Nebulosas [4], técnicas baseadas em Redes Neurais Construtivas [5] e os modelos clássicos de séries temporais propostos por Box e Jenkins [6], como é o caso do modelo PREVIVAZ do Cepel [7]. Estas previsões são utilizadas para definição de estratégia das empresas de energia no planejamento de atividades como o gerenciamento energético, definição de diretrizes operacionais, programação anual de manutenção, previsão orçamentária anual, planejamento de investimentos e estudos de viabilidade econômica. No caso do sistema brasileiro, o ONS utiliza estas previsões para estimar o enchimento de reservatórios de hidrelétricas e subsidiar o planejamento da operação para o horizonte anual, sinalizando o

comportamento dos reservatórios, o risco de déficit de energia para cada subsistema e as perspectivas de possível racionamento de energia elétrica. Observa-se, entretanto, que, principalmente em relação aos modelos estocásticos de previsão, independente da última vazão natural média mensal observada, após um determinado número de passos à frente a previsão realizada se aproxima da média de longo termo – MLT, de forma que os erros médios absolutos das diferentes técnicas se aproximam qualitativamente. Em outras palavras, após alguns passos no horizonte de previsão de longo prazo, as previsões tendem a indicar a média histórica [5]. Segundo estes autores uma evolução das previsões climáticas e a incorporação de suas informações aos atuais modelos de previsão podem resultar em ganhos significativos às previsões de longo prazo.

Previsões de médio prazo são aquelas realizadas para horizontes variando de uma semana até cinco anos, a partir de informações em bases diária, semanal ou mensal. Estas previsões têm por objetivo subsidiar o Programa Mensal de Operação - PMO, realizado pelo ONS, e suas revisões semanais, auxiliando no processo de otimização dos recursos naturais nos reservatórios e no processo de uso múltiplo dos reservatórios. Novamente os autores de [5] afirmam que, à medida que houver uma evolução nas tecnologias de previsão de precipitação que permita ampliar o horizonte atual, haverá um ganho elevado nos resultados das previsões de vazões de médio prazo.

Para o horizonte de curto prazo são realizadas estimativas de vazões naturais médias diárias para um horizonte de até 14 dias à frente tendo por base o histórico de vazões naturais médias diárias, segundo a literatura, em sua grande maioria baseado nos dados de balanço hídrico, utilizando métodos determinísticos, como modelos chuva-vazão, ou através de modelos estocásticos. Previsões de curto prazo são essenciais ao planejamento da operação, uma vez que fornecem subsídios para programação da geração, abrangendo coordenação hidrotérmica, despacho econômico e programação da manutenção. Para o caso específico do despacho do sistema elétrico brasileiro, o ONS utiliza previsões de vazões de curto prazo, para programação diária da operação do Sistema Interligado Nacional - SIN, para monitoramento e controle de eventos extremos (cheias e secas) e no auxílio à tomada de decisão para garantia do uso múltiplo da água.

A maioria dos modelos atuais de previsão hidrológica são do tipo auto-regressivos, construídos e operados independentemente para cada reservatório. A construção desses modelos adota como premissa básica a independência mútua das séries de afluência. Embora

essa suposição possa garantir que em previsões de curto prazo (menores do que cinco dias) seja mantida a variabilidade espacial observada nos dados históricos, a persistência da série de vazões e o uso de informações passadas tende a explicar a pequena variância de vazões de longo prazo, o que pode acarretar na violação dessa premissa [8]. Em geral, esses modelos têm o seu desempenho reduzido quando a antecedência (*lead time*) das previsões é superior a duas semanas, como pode ser observado nos relatórios do ONS que avaliam anualmente o desempenho das previsões de vazões [9]. Além disso, as previsões feitas em escalas semanais são independentes daquelas feitas em escala mensal, ou seja, nenhuma informação quantitativa das previsões mensais é utilizada no modelo semanal e nas suas previsões, embora as políticas operacionais multiescala (por exemplo, regras de operação do dia seguinte e curvas de aversão ao risco) estejam conectadas temporalmente.

Dada a importância da previsão hidrológica de curto prazo, diversos estudos vêm abordando este tema nos últimos anos, através de diferentes perspectivas. Para a previsão de vazões afluentes a um reservatório na operação de sistemas hidráulicos, de modo a permitir melhor aproveitamento hídrico [10]–[12], para previsões em sistemas de proteção contra inundação [13]–[16] e também para previsões ligadas a agricultura e irrigação [17].

Os modelos hidrológicos, na tentativa de representar o comportamento dos fenômenos naturais, utilizam como um dos insumos fundamentais para sua execução as vazões naturais médias diárias, semanais ou mensais, dependendo do horizonte de estudo e da aplicação desejada. Algumas vezes se faz necessário utilizar um histórico de série de vazões naturais e outras vezes se utiliza simplesmente alguns valores previstos para períodos à frente, principalmente para analisar a operação dos reservatórios através de uma simulação ou até mesmo determinar qual deverá ser sua operação ótima para atender uma determinada condição de armazenamento e demanda para os diferentes usos a partir dessa afluência prevista [17]. Um dos principais problemas enfrentados na modelagem de sistemas hídricos é o risco associado a variabilidade natural do regime hidrológico. Usinas hidrelétricas possuem características de produção não lineares e suas vazões afluentes são variáveis aleatórias, levando assim a um problema estocástico não linear.

Observa-se que, em se tratando de séries temporais de comportamento não linear, a metodologia de Redes Neurais Artificiais - RNAs - tem sido largamente adotada para prever valores futuros com bases em valores passados [18], como é o caso da previsão de comportamento hidrológico. Isto é decorrente da grande capacidade de Redes Neurais

Artificiais para tratar relações não lineares de entrada-saída, devido a sua habilidade de aprendizado e capacidade de generalização, associação e busca paralela. Além disso, ao contrário dos modelos lineares clássicos, as Redes Neurais apresentam poucas premissas básicas a serem verificadas, aumentando assim a sua flexibilidade e robustez.

Como citado anteriormente, um dos principais produtos dos processos de planejamento e programação da operação do SIN é o PMO. Este processo é responsável pelos estudos de otimização e simulação da operação do SIN, onde são estabelecidas políticas de geração térmica e intercâmbios inter-regionais para as semanas analisadas e também são fornecidas metas e diretrizes a serem seguidas pela Programação Diária da Operação Eletroenergética e pela Operação em Tempo Real. Para a elaboração do PMO e de suas revisões, são utilizadas as previsões de vazões semanais para todos os locais de aproveitamentos hidrelétricos, da primeira à última semana operativa do respectivo mês. A cada revisão, as previsões de vazões para todas as semanas remanescentes para o fechamento do mês são sempre revistas, sendo fundamental a qualidade da previsão de vazões para a próxima semana operativa. As previsões diárias são realizadas com o objetivo de completar a série de vazões da semana em curso. O PMO utiliza previsões diárias realizadas a partir dos modelos chuva-vazão do ONS ou informadas pelos próprios agentes de geração.

Pequenas Centrais Hidrelétricas – PCH’s – são um caso particular de estudo dentro do SIN. Devido as suas características, elas não integram o despacho centralizado promovido pelo ONS, possuindo liberdade de realizar o planejamento de geração de forma autônoma.

O planejamento energético é de fundamental importância para qualquer usina, independentemente de sua escala, com objetivo de racionalização do uso do recurso natural, operação segura de barragens em áreas habitadas e correto planejamento estratégico. Ressalta-se que no caso particular de PCH’s, a tomada de decisão deve ser de resposta rápida, pois o cenário climático é extremamente variável e a capacidade de regulação de vazão destas usinas é reduzida ou até mesmo inexistente, no caso de usinas tipo fio d’água. Assim, previsões de variações climáticas que requeiram alteração no planejamento da geração devem ser realizadas em escala de tempo adequada, a tempo de fornecer uma resposta eficiente e segura para operação da planta.

Estudos quanto a aplicabilidade da previsão hidrológica utilizando o método de Redes Neurais Artificiais em reservatórios de pequena e média capacidade de regulação são escassos

e recentes, uma vez que a grande maioria dos estudos encontrados conduz a análise para grandes reservatórios do SIN, com larga capacidade de regulação [5], [12], [15], [19]–[25].

A operação ótima de sistemas complexos como o de uma hidrelétrica deve contemplar uma estratégia de geração que seja capaz de atender a máxima demanda, mas sempre considerando as restrições de seus recursos, ou seja, deve determinar uma produtividade ótima que respeite as limitações, economize matéria prima e reduza custos.

A otimização do planejamento de curto prazo tem sido assunto de discussão recorrente em estudos recentes, resultando em uma vasta e diversificada literatura. Modelos de programação matemática constituem os métodos mais frequentemente adotados para o problema, sendo que são sugeridas diversas técnicas tais como programação dinâmica [26], o princípio da otimalidade progressiva [27], algoritmos de fluxo de redes [28] e relaxação Lagrangeana [29]. Outros trabalhos propuseram uma formulação representada através de equações de fluxo de carga [30], [31]. Entretanto, foi observado que estes trabalhos possuem como foco de otimização o rendimento dos conjuntos turbina-gerador, minimizando a adução de água, não objetivando otimização do comportamento limnométrico de reservatório, como é o tema deste trabalho. Trabalhos de otimização de reservatórios frequentemente enfocam operação de múltiplos reservatórios [32]–[34], diferentemente do enfoque dado neste estudo.

A determinação da operação ótima e segura consiste na definição de um conjunto de controles que minimizam um determinado critério de despacho (por exemplo, vertimentos indevidos de água - desperdício) garantindo simultaneamente a operação dos reservatórios dentro dos seus limites operativos. Equacionada desta forma, a determinação do despacho ótimo pode ser definida como um problema de otimização (programação) não-linear com restrições, existindo na literatura métodos clássicos de solução, tais como métodos de programação não-linear [35] e programação quadrática [36].

Os métodos clássicos de programação não-linear vêm apresentando resultados satisfatórios como solução ao problema de otimização, contudo, apresentam ainda algumas limitações, tais como estagnação em mínimos locais [37]. Visando superar tais limitações, técnicas de inteligência computacional inspiradas na natureza, como algoritmos genéticos [38] e enxame de partículas [39], vêm sendo aplicadas recentemente como solução para problemas de otimização.

Assim, como forma de enriquecer o arcabouço de estudos sobre planejamento ótimo de curto prazo, este trabalho tem por objetivo avaliar o desempenho conjunto da técnica de Redes Neurais com o método de otimização por Enxame de Partículas. Para tanto, foi desenvolvido um modelo baseado em Redes Neurais Artificiais para previsão do comportamento do nível do reservatório de barragens para um horizonte de 24 (vinte e quatro) horas à frente. A metodologia foi avaliada considerando dados para o trecho da Bacia do Rio Preto incremental a uma Pequena Central Hidrelétrica – PCH, escolhida como objeto de estudo devido a característica técnica adequada aos questionamentos levantados e a existência de uma larga base de dados, necessária para treinamento da Rede Neural Artificial. A escala de previsão diária foi escolhida devido a particularidade de baixa regulação de vazões de PCH's e, como será observado neste trabalho, devido a disponibilidade de informações reais de precipitação dentro deste intervalo, não requerendo a utilização de dados de previsão cuja manifestação é incerta.

Com a Rede Neural validada, é possível prever o comportamento limnimétrico futuro do reservatório dentro do horizonte de previsão para diferentes cenários de geração, assim, a segunda parte deste trabalho se dedicou a construção de um sistema para geração e testes de diferentes cenários de geração, para auxílio no planejamento ótimo do despacho da central. O sistema trabalha com a apresentação de dois diferentes cenários, o primeiro considerando despacho *flat*, ou seja, mesmo valor de produção para todas as horas de um determinado dia, e o segundo utilizando a técnica Otimização por Enxame de Partículas para otimização do despacho em base horária.

Este trabalho difere dos estudos elaborados anteriormente ao concatenar a previsão hidrológica de curto prazo através da técnica de Redes Neurais Artificiais, com a metodologia de Otimização por Enxame de Partículas para elaboração de sugestão de despacho ótimo de usinas hidrelétricas, objetivando auxílio da programação diária, e também por modelar a previsão focando na análise do comportamento limnimétrico de reservatórios.

## ***1.2. OBJETIVO***

Este trabalho tem por objetivo a elaboração de um método para auxílio no planejamento do despacho diário de Pequenas Centrais Hidrelétricas. Para isso, inicialmente, foi construído um modelo baseado em Redes Neurais para previsão horária do comportamento limnimétrico de reservatórios em um horizonte de 24 horas à frente, utilizando para treinamento as informações referentes ao trecho da Bacia do Rio Preto incremental à uma Pequena Central

Hidrelétrica para: (1) verificar a viabilidade da utilização de Redes Neurais Artificiais para previsão de comportamento limnimétrico de barragens de pequena e média acumulação em condições normais do rio, e; (2) estudar o impacto da utilização da precipitação real observada à montante para previsão do comportamento do reservatório em comparação com previsão utilizando apenas a série temporal histórica. Foram utilizadas Redes Neurais Artificiais do tipo *multi-layer perceptron* - MLP, treinada com o algoritmo de aprendizado supervisionado de regularização Bayesiana, a partir das informações de medição linimétrica, precipitação de montante e vazão de jusante observadas. A Rede Neural Artificial construída foi validada e utilizada como informação de teste para o método de auxílio no planejamento ótimo do despacho. Para construção do sistema, inicialmente define-se as curvas-guias de despacho sendo o nível mínimo associado aos melhores rendimentos do conjunto turbina-gerador e o nível máximo associado ao volume de espera ideal, em reservatórios com esta característica, ou simplesmente o nível máximo para usinas tipo fio d'água. Com a definição da faixa operativa ideal, o método testa diferentes configurações de geração em dois cenários distintos: (1) despacho *flat*, isto é, valores de geração iguais para todo o horizonte de previsão e, (2) despacho otimizado, elaborado através da técnica de Otimização por Enxame de Partículas, aplicando ambos os cenários em base horária a Rede Neural para previsão dos níveis resultantes das diferentes configurações de geração, verificando extrapolações da faixa operativa ideal.

Portanto, essa dissertação tem como objetivos apresentar, implementar e avaliar técnicas promissoras de inteligência computacional e métodos estatísticos para previsão horária do comportamento limnimétrico de reservatórios no um horizonte de 24 horas à frente e apresentar, implementar e avaliar técnicas promissoras de otimização para programação diária de PCH's.

### **1.3. ESTRUTURA DO DOCUMENTO**

Este documento está dividido em 6 capítulos, referências bibliográficas e anexos.

O capítulo 1, *INTRODUÇÃO*, apresenta a motivação e os objetivos do estudo, além da estrutura do mesmo.

O capítulo 2, *MÉTODOS PARA PROGRAMAÇÃO DIÁRIA DE PEQUENAS CENTRAIS HIDRELÉTRICAS*, descreve diferentes metodologias de previsão hidrológica utilizadas na área de geração de energia elétrica, dando enfoque as técnicas utilizadas, bem como métodos empregados no despacho diário de usinas, destacando o estado da arte em programação de curto prazo de PCH's.

O capítulo 3, *REFERENCIAL TEÓRICO*, apresenta uma revisão do referencial teórico que foi utilizado para desenvolvimento do sistema para programação diária de pequenas centrais hidrelétricas, sendo uma introdução a modelagem de sistemas hídricos, a metodologia de Redes Neurais Artificiais, e os conceitos e lógica de funcionamento da técnica de Otimização por Enxame de Partículas.

O capítulo 4, *MATERIAIS E MÉTODOS*, demonstra o desenvolvimento do sistema para auxílio no planejamento do despacho diário de Pequenas Centrais Hidrelétricas, abordando a construção do sistema de previsão de comportamento limnimétrico de reservatórios a partir da metodologia de Redes Neurais Artificiais e a união da metodologia de RNA com a de Otimização por Enxame de Partículas para construção do cenário otimizado de despacho de PCHs. Os principais resultados obtidos nas avaliações dos métodos propostos também são encontrados nesse capítulo.

O capítulo 5, *CONCLUSÕES*, apresenta as conclusões do estudo realizado e, por fim, são feitas propostas de desenvolvimento de trabalhos futuros com sugestões para a continuidade deste.

## **2. MÉTODOS PARA PROGRAMAÇÃO DIÁRIA DE PEQUENAS CENTRAIS HIDRELÉTRICAS**

Neste capítulo, serão apresentadas metodologias de previsão hidrológica utilizadas na área de geração de energia elétrica, dando enfoque as diferentes técnicas utilizadas, bem como métodos empregados no despacho diário de usinas, destacando o estado da arte em programação de curto prazo de Pequenas Centrais Hidrelétricas.

No âmbito do setor elétrico, [40] afirmaram que a previsão de vazões afluentes aos reservatórios permite que os diferentes modelos de operação, otimização e simulação energética possam ser utilizados para avaliar as condições operacionais das usinas hidrelétricas. Essas previsões de vazões permitem que sejam tomadas decisões que minimizem o efeito de eventos extremos e maximizem a utilização do volume de espera dos reservatórios, desde que realizadas com relativa exatidão e antecedência.

### ***2.1. SISTEMAS DE PREVISÃO HIDROLÓGICA***

A vazão num rio ou canal é um processo complexo influenciado por fatores como a topografia, a cobertura vegetal, tipos de solo, características do canal, presença de aquíferos, distribuição da precipitação, área urbanizada. Os projetos de engenharia e análise de impacto no meio ambiente frequentemente requerem a estimativa da vazão, ou suas propriedades estatísticas em lugares onde não se tem dados de vazão.

Para sistemas de previsão hidrológica, os principais dados utilizados como fonte de entrada, seja para modelos conceituais ou para modelos empíricos, são os valores de nível à montante, informação de precipitação e previsão de precipitação [41].

A escolha do modelo mais adequado ao problema da bacia pode ser feita com base na área de contribuição da bacia. Para bacias com área maior que 10.000 km<sup>2</sup>, o uso da teoria da propagação da onda de cheia com coleta de dados de níveis a montante é suficiente para se ter uma previsão com boa antecedência e precisão. Para bacias de médio porte a previsão deve ser feita com os dados de precipitação observados, e para bacias com área menor que 1.000 km<sup>2</sup>, somente com previsão de precipitação é possível desenvolver um modelo que forneça tempo razoável de antecedência à inundação [41].

Uma grande variedade de métodos tem sido desenvolvida para o propósito de previsão de vazão, incluindo modelos paramétricos e os modelos empíricos. Muitos modelos são

baseados na metodologia Box e Jenkins, a qual assume relações lineares entre as variáveis do sistema [6]. A utilização de modelos de séries temporais em análise de previsão de séries climatológicas é bem aceita por pesquisadores, como no trabalho de [42] que utilizou o conceito de séries temporais para descrever a série de vazão da represa de Furnas ou no estudo de [43] que utilizou modelos de séries temporais para análise e previsão de precipitação mensal no município de Lavras-MG.

Dentre estes métodos, os modelos de transformação chuva-vazão possuem destaque, tendo como grande vantagem a utilização do dado de precipitação que é, geralmente, mais abundante e promove uma maior antecedência para bacias pequenas, onde o tempo de concentração é menor não permitindo uma previsão em tempo real por observação de níveis a montante do ponto desejado. Por outro lado, a principal desvantagem deste modelo é necessitar que a observação pluviométrica seja transformada em escoamento, o que implica em uma série de incertezas nos parâmetros de entrada, associadas a coeficientes de permeabilidade, declividades, cobertura do solo, distribuição espacial e temporal das chuvas e curva-chave [41].

Modelos matemáticos convencionais, como o modelo de tanque, têm sido utilizados para a previsão hidrológica [21]. Porém, esses métodos levam muito tempo para calibrar e validar seus parâmetros, além de não realizarem com precisão previsões em condições normais do rio, uma vez que o objetivo destes sistemas é previsão para a operação de segurança em condições de rios inundados.

Especificamente para a previsão de comportamento hidrológico, diversos estudos conduzidos utilizam Redes Neurais, com destaque para [19], [44]–[46]. O emprego dessa tecnologia ganhou espaço também na área de recursos hídricos, onde, na maioria das vezes, a utilização da técnica na previsão climatológica apresentou resultados compatíveis ou superiores às técnicas tradicionais [47]. Isto é explicado pelo fato que as Redes Neurais Artificiais – RNAs – são métodos matemáticos com elevada capacidade para lidar com fenômenos complexos não lineares. Além disso, as Redes Neurais podem ajustar seus parâmetros, chamados pesos, automaticamente usando dados de entrada e saída [48], sendo por isso que modelos utilizando RNAs possuem elevada sinergia para estudos de comportamento em barragens, detentoras de elevado histórico de informações referente a sua operação. As referências [49]-[50] afirmam que RNAs com três camadas são capazes de aproximar qualquer função com características não lineares. Além disso, ao contrário dos modelos lineares clássicos, as Redes Neurais apresentam poucas premissas básicas a serem verificadas, aumentando assim a sua flexibilidade e robustez.

Por esta razão, muitos estudos recentes da área de previsão hidrológica são baseados na metodologia de Redes Neurais.

A aplicação da metodologia de Redes Neurais vem sendo objetivo de inúmeras de pesquisas, servindo como uma valiosa ferramenta. Especificamente, diversos estudos conduzidos utilizam Redes Neurais para a previsão hidrológica [19], [44]–[46]. [51], apresentando resultados que mostram a potencialidade da técnica.

A referência [20] utiliza o método de Redes Neurais para realizar previsões de vazões na bacia hidrográfica do rio *Red River Valley*, no Canadá. Estes autores testaram diferentes estruturas de RNAs e comparam os resultados com outros modelos empíricos. Em suas conclusões ele afirmam que as RNAs apresentam os melhores resultados e que os resultados são dependentes da estrutura e dos dados de entrada.

O trabalho apresentado em [52] exemplifica uma comparação semelhante. Estes autores utilizaram RNA para prever a vazão média mensal em três bacias hidrográficas no *Kansas*, EUA. Para isso eles modelaram RNAs do tipo *feedforward* e recorrentes utilizando como dados de entradas a temperatura e chuva mensal. Eles concluíram que as RNAs recorrentes apresentaram os melhores resultados e que bons resultados são obtidos mesmo para um pequeno número de interações no treinamento.

Em [22] os autores utilizaram a técnica de RNA para fazer a modelagem da transformação chuva-vazão. O objetivo era avaliar o desempenho da técnica comparando com alguns modelos de chuva-vazão tradicionais. Dependendo da natureza do problema, a RNA pode ter múltiplas entradas e múltiplas saídas. O autor utilizou em seu trabalho múltiplas entradas, mas apenas uma saída. A rede usada foi a MLP *feedforward*, por ser considerada como boa função aproximativa [53]. A forma da rede foi testada usando diferentes tipos de informações de entrada, como exemplo, chuva, chuva sazonal histórica e informação do vizinho mais próximo. Foi aplicada a técnica para quatro diferentes cenários nos dados de seis bacias hidrográficas, onde alguns ou todos esses tipos de entradas foram utilizadas. A performance da técnica foi comparada com modelos que utilizam informações de entrada similar: o modelo linear simples (*Simple Linear Model* - SLM), o modelo de perturbação linear baseado na sazonalidade (*Linear Perturbation Model* - LPM) e modelo de perturbação linear do vizinho mais próximo (*Nearest-Neighbor Linear Perturbation Model* - NNLPM). Os autores classificaram os resultados com a RNA como promissores no contexto de modelagem chuva-

vazão, com a ressalva de que, como todos os modelos, tem resultados variáveis, ou seja, dependem da aplicação.

No Brasil, a referência [54] utiliza o modelo SMAP, do inglês *Soil Moisture Accounting Procedure*, para estimar vazões na escala mensal na Bacia do Rio Paraobepa, afluente do São Francisco, sendo constatado que o modelo possui desempenho adequado para tal objetivo. Estudos como os de [10] e [55], realizados nas bacias brasileiras do Jaguaribe e do Iguaçú, respectivamente, também comprovaram a eficácia do modelo para estimativa das vazões de cursos de água.

Em seu estudo, Cataldi et. al. [56] elaboraram previsões para a Usina Hidroelétrica – UHE - Três Marias, na Bacia do Rio São Francisco, em um horizonte de 12 dias, utilizando informações observadas de postos pluviométricos, fluviométricos e de vazão natural. Para isso, calibrou dois modelos de Redes Neurais, uma MLP com algoritmo de retropropagação, e uma rede do tipo *Non-Linear Sigmoidal Regression Blocks Networks* (NSRBN). Os resultados obtidos pelos autores possibilitaram a obtenção da previsão de vazões com desempenhos superiores às dos modelos estatísticos, ratificando o potencial da técnica.

Os autores de [57] realizaram um estudo para os aproveitamentos hidrelétricos de Foz do Areia e Salto Santiago na Bacia do Rio Iguaçú. Tendo como informações de partida a precipitação observada e prevista, além das vazões naturais verificadas, utilizaram técnicas de mineração de dados e de Redes Neurais com treinamento bayesiano para o balizamento da escolha da melhor previsão de vazões naturais com horizonte de dez dias à frente. Os resultados obtidos demonstraram que essa pode ser uma solução eficaz para a diminuição dos erros de previsão em horizonte semanal da vazão natural na bacia.

A referência [58] utiliza uma RNA MLP *feedforward* para desenvolver um método de cálculo para vazão a partir da precipitação para vazões baixas, objetivando uma melhor análise sobre o período seco. O algoritmo utilizado foi o *backpropagation*, utilizando um ajuste em tempo real. Para o autor, não só a precipitação histórica é importante na previsão de vazões, mas também a evapotranspiração e a infiltração, por isto ele calibrou a entrada da rede utilizando a precipitação nos instantes de tempo atual e anterior, e também o número de dias de chuva no período.

No que se refere a previsão hidrológica no Brasil, o Centro de Pesquisas de Energia Elétrica – Cepel – desenvolveu um conjunto de modelos e programas computacionais para

elaboração de previsões de afluições diárias, semanais e mensais. O Modelo PREVIVAZH – Modelo de Previsão de Vazões Diárias foi desenvolvido visando à obtenção das previsões de vazões diárias, até 13 dias à frente. As previsões são baseadas na desagregação, em intervalos diários, das previsões de afluições semanais obtidas pelo modelo PREVIVAZ. A metodologia de desagregação não paramétrica das afluições semanais faz uso das últimas afluições diárias e de séries sintéticas de vazões diárias. O Modelo PREVIVAZ – Modelo de Previsão de Vazões Semanais foi desenvolvido visando à obtenção das previsões de afluições semanais, até seis semanas à frente. O modelo analisa a série histórica de afluições semanais de cada aproveitamento hidrelétrico e seleciona, para cada semana, um modelo dentre diversas alternativas de modelagem estocástica. Essas alternativas baseiam-se nos modelos de séries temporais propostos por [6], mais especificamente, em modelos autorregressivos com ou sem componente de média móvel (AR e ARMA, respectivamente). Estes modelos são construídos como função da informação passada em diferentes passos de tempo (*lags*), podendo ou não apresentar estrutura de correlação periódica. A estrutura de correlação temporal da série de vazões semanal é definida em intervalos de diferentes durações (semanal, mensal, trimestral e semestral).

O Modelo PREVIVAZM – Modelo de Previsão de Vazões Mensais foi desenvolvido com o objetivo de obter previsões de vazões mensais, até doze meses à frente. O modelo segue a mesma abordagem do modelo semanal PREVIVAZ. Portanto, para cada aproveitamento hidrelétrico, analisa a sua série histórica de afluições mensais e seleciona, para cada mês, um modelo estocástico entre diversas alternativas de modelagem [7].

A referência [4] realizou estudos relativos à previsão de vazão em tempo real, concentrando-se no uso de duas RNA: a Rede de Kohonen e Rede MLP com algoritmo *backpropagation*. Estas redes foram utilizadas para o reconhecimento das informações relativas aos dados de precipitação e vazão a serem recuperadas para realização das previsões de vazões diárias, observando-se qual era o potencial de utilização das duas redes. Com base nos resultados obtidos pela rede de Kohonen e a rede MLP uma outra análise comparativa foi realizada para avaliar o desempenho de ambas na tarefa de previsão chuva-vazão. Os resultados mostraram que o Método dos Vizinhos Mais Próximos e a Rede Multi-Camadas apresentaram uma performance superior a Rede de Kohonen para previsão chuva-vazão.

Recentemente, na literatura internacional, algumas publicações científicas vêm utilizando os modelos de RNAs para a previsão de vazões, em diferentes horizontes temporais e com distintas configurações de dados de entrada [21], [59], [60].

Observa-se que a maioria dos estudos conduzidos no Brasil tem por objetivo a aplicação a grandes bacias, e a ênfase dos mesmos está concentrada em duas frentes: aqueles dirigidos ao gerenciamento de reservatórios [5], [11], [61], [62] e os voltados ao impacto das mudanças climáticas [62]–[64], atingindo bons resultados para estes casos.

Aplicações dirigidas a modelagem do comportamento limnimétrico de reservatórios de acumulação diária, uma vez que em grandes reservatórios este comportamento possui pouca variabilidade no curto prazo, são escassas e recentes, reforçando a relevância do estudo aqui apresentado.

## ***2.2. MÉTODOS PARA OPERAÇÃO DE RESERVATÓRIOS***

Existem diferentes regras de operação de reservatórios, mas todas indicam o volume do reservatório ou a vazão defluente que se pretende atingir em determinados períodos de tempo como o diário, semanal ou mensal [65]. Estas regras visam atender os requisitos de vazão defluente e demandas do sistema para otimizar determinados objetivos [66].

Os trabalhos referentes ao planejamento da operação de curto prazo de um sistema de geração são recentes, mas fazem parte de um universo relativamente grande de pesquisa. A grande maioria das referências que são encontradas na literatura tratam de sistemas puramente termelétricos devido aos altos custos envolvidos em sua operação e logicamente à necessidade de maximização da produtividade. Pesquisas sobre sistemas predominantemente hidrelétricos representam um conjunto menor, mas significativo, dada a importância da utilização ótima de recursos naturais [26]–[34].

A geração de energia e o controle de cheias por um reservatório são objetivos conflitantes. Para atender estes objetivos, o nível d'água no reservatório é reduzido durante o período chuvoso, para permitir amortecer vazões afluentes altas. Em função disso, ocorre uma redução da produção energética, se comparado ao cenário de maximização do nível d'água no reservatório, devido a diminuição da coluna (queda) d'água imposta a turbina, que representaria a operação otimizada do ponto de vista da geração de energia. O volume criado no reservatório pelo rebaixamento do nível é denominado de volume de espera.

O volume de espera pode ser constante ao longo do ano, ou variável de acordo com a sazonalidade das chuvas. Valores máximos de volumes de espera são necessários na época de maior precipitação e valores mínimos podem ser adotados durante os meses de pouca chuva. A curva definida pela relação entre o nível d'água necessário para garantir um determinado volume de espera e a época do ano é chamada de curva-guia para controle de cheias. Esta curva representa uma regra de operação simples para controle de cheias, basicamente ela determina que se o nível d'água no reservatório estiver acima da curva-guia é necessário verter, se estiver abaixo não é necessário verter.

A grande maioria dos estudos sobre métodos de otimização da operação de reservatórios trabalha com a metodologia de definição de regras de operação chamadas curvas-guia, que consiste na divisão do volume útil do reservatório em diferentes zonas que possuem políticas de descargas específicas [67], em conjunto com a técnica de otimização denominada parametrização, simulação e otimização, para otimização das regras de operação de um reservatório [11], [68]–[70] ou de um sistema de reservatórios [71]–[73]. A distribuição destas zonas de operação pode ser feita de forma constante ao longo do ano ou variando de forma sazonal.

O trabalho apresentado em [74] conclui que, nos trabalhos direcionados para minimizar o custo da geração termelétrica, a geração hidrelétrica era deixada apenas como uma complementação já fixada de antemão pelos modelos de longo e médio prazo, na forma de metas de geração. Foram nestas abordagens, porém, que a dinâmica dos reservatórios das usinas hidrelétricas ganhou relevância, ainda que a representação da função de geração hidrelétrica tenha ficado limitada apenas ao produto da vazão turbinada pela produtividade média da usina hidrelétrica [75].

A referência [76] apresenta uma metodologia de otimização da operação em tempo real das usinas da bacia do *Colorado River*. O autor representou as turbinas através como função simplificada de seu engolimento em razão da potência gerada, atualizada pela altura de queda de cada usina, sendo o engolimento utilizado como critério de otimização.

Os artigos [77], [78] utilizam Redes Neurais artificiais para minimizar a função objetivo relacionada com os custos operativos de usinas hidrelétricas com custo computacional inferior ao de técnicas como programação dinâmica.

Nilsson e Sjelvgren [79] construíram um modelo para otimização do programa de geração de um modelo predominantemente hidráulico e com possibilidade de intercâmbio de energia com vizinhos através de programação dinâmica. Para isso atribuíram custo para a partida de máquina e modelaram o engolimento marginal através de uma função linear.

Wong et. al. [80] apresentam uma metodologia para resolução do problema de planejamento de curto prazo considerando os pontos de vista térmico e hidráulico. Utilizando a técnica *simulated annealing* os autores foram capazes de determinar soluções ótimas globais para o planejamento diário da operação com necessidades de reserva.

No Brasil, a referência [81] propõe um modelo de pré-despacho que minimiza as perdas no sistema hidráulico de geração e de transmissão, utilizando método heurístico para definição do despacho e técnica de decomposição para equacionamento do pré-despacho. Os autores dedicaram especial atenção ao equacionamento da geração hidráulica, com detalhamento das perdas neste sistema.

Lyra e Ferreira [82] utilizaram programação dinâmica para otimização do planejamento de curto prazo das usinas ao longo do rio Iguaçu com ganhos da ordem de 1,5% devido ao acoplamento entre as unidades. Os autores realizam uma importante contribuição para a geração hidrelétrica ao comprovar a hipótese de que é possível obter ganhos energéticos com a adoção de regras não convencionais no despacho.

Finardi e Da Silva [83] apresentaram uma modelagem para despacho de unidades geradoras onde consideraram o nível do reservatório constante. A altura de queda é obtida pela diferença entre o nível do reservatório e o nível do canal de fuga para um valor de meta de descarga, que é selecionado por meio da técnica de *Branch and Bound*. Após a seleção das configurações factíveis de unidades geradoras para o atendimento da descarga meta, a técnica busca definir qual é a configuração de unidades geradoras e o nível de geração em cada uma das unidades geradoras que compõem essa configuração e que leva à maximização da geração hidrelétrica através da técnica de gradiente projetado.

Não foram encontrados, a priori, estudos que busquem otimizar o comportamento limnimétrico de reservatórios através da Técnica de Otimização por Enxame de Partículas, potencializando a relevância do estudo aqui desenvolvido.

### **3. REFERENCIAL TEÓRICO**

Neste capítulo é apresentada uma revisão do referencial teórico que foi utilizado para desenvolvimento do sistema para programação diária de pequenas centrais hidrelétricas. Inicialmente é apresentada uma introdução a modelagem de sistemas hídricos, seus principais conceitos e dificuldades inerentes. Em seguida é apresentada a metodologia de Redes Neurais Artificiais, que foi utilizada para desenvolvimento do sistema de previsão do comportamento limnimétrico de reservatórios. Por fim, são demonstrados os conceitos e lógica de funcionamento da técnica de otimização por Enxame de Partículas, utilizada para geração do cenário otimizado de despacho.

#### **3.1. MODELAGEM DE SISTEMAS HÍDRICOS**

Modelo é uma representação simplificada de um objeto ou sistema, de fácil acesso e uso, desenvolvido com o objetivo de entendê-lo e encontrar respostas para diferentes circunstâncias [17].

Os modelos hidrológicos são ferramentas matemáticas utilizadas para representar o comportamento dos elementos que compõem o ciclo hidrológico, de modo a produzir resultados próximos aos ocorridos na natureza. Tais modelos apresentam incertezas, geralmente, relacionadas com a incapacidade de representar alguns processos, com a existência de dados deficientes, e com a variação dos parâmetros para representar o sistema.

Para se compreender a complexidade envolvida na modelagem dos processos hídricos podemos analisar o ciclo hidrológico de forma simplificada na Figura 3.1 [17], onde são retratadas as diversas parcelas que participam da composição da vazão num curso d'água: precipitação direta sobre o rio  $P$ , precipitação no solo da bacia com a formação de um escoamento superficial  $S$ , escoamento subsuperficial  $SS$  formado pela infiltração  $I$ , lençol freático ou subterrâneo formado pela percolação  $PR$ , a evaporação sobre os rios e lagos  $E$  as retiradas de água para os mais diferentes usos como irrigação, abastecimento e dessedentação de animais  $U$ .

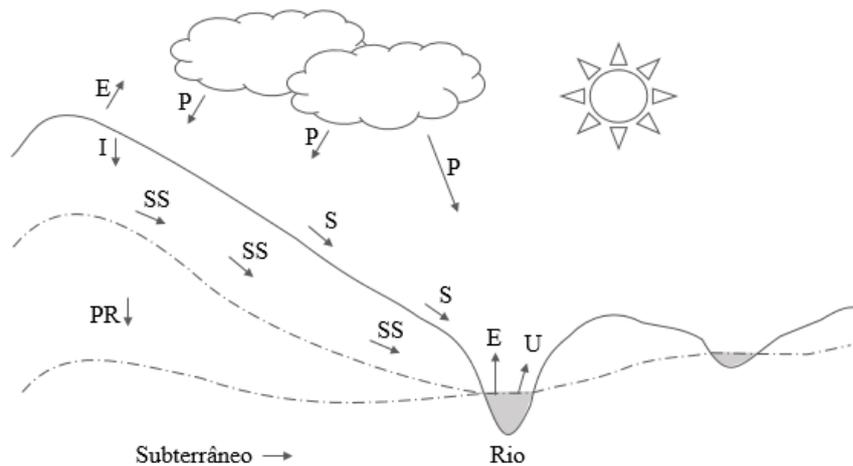


Figura 3.1 – Esquema básico ciclo hidrológico. (Adaptado de [17])

A modelagem hidrológica é utilizada para atender as seguintes finalidades:

- Fornecer dados para projetos de engenharia: seu uso é comum na extensão de séries de dados fluviométricos, uma vez que a disponibilidade de dados pluviométricos costuma ser maior que os fluviométricos.
- Simular vazões em cursos de água de bacias submetidas a intervenções, pois conseqüentemente suas características estão em processo de alteração.
- Prever vazões que subsidiem o gerenciamento de barragens e sistemas de alerta de cheias.
- Analisar o impacto de obras hidráulicas em cursos de água.
- Avaliar o impacto de intervenções antrópicas em bacias hidrográficas.
- Estudar, equacionar e reproduzir as diversas fases do ciclo hidrológico, objetivos inerentes às atividades de pesquisa.

Os modelos hidrológicos podem ser classificados em [17]:

- Modelo Determinístico: as equações utilizadas para descrever as fases do ciclo hidrológico não contêm componentes aleatórias, assim, para uma determinada situação inicial, o modelo sempre produzirá a mesma resposta final.
- Modelo Estocástico ou Probabilístico: as formulações utilizadas na descrição do fenômeno contêm variáveis aleatórias que seguem alguma distribuição probabilística.
- Modelo com embasamento físico: reproduz todos os processos físicos através de equações matemáticas. A característica marcante deste modelo é que os parâmetros e as constantes das equações podem ser medidos ou determinados a priori, não necessitando de calibração. Sua utilização é restrita em função da dificuldade na obtenção de todos os parâmetros necessários.
- Modelo Conceitual e Semiconceitual: está baseado no entendimento conceitual do ciclo hidrológico, com a utilização de funções empíricas para explicar alguns dos subprocessos envolvidos. Procura representar, de maneira simplificada, todos os processos físicos conhecidos do ciclo hidrológico.
- Modelo Empírico ou caixa preta (*Black Box*): os resultados são obtidos através de ajustes de funções matemáticas. Estas funções não têm a finalidade de explicar os processos envolvidos, são apenas representações de um ajuste estatístico.
- Modelo Contínuo: desenvolvido para simular longos períodos de tempo. Este tipo de modelo deve considerar algum tipo de acumulação de umidade no solo.
- Modelo de Evento: aquele que simula um evento individual, dadas as condições iniciais.
- Modelo Concentrado: considera os dados de entrada e os parâmetros representativos da bacia como valores médios, válidos para toda área de estudo.
- Modelo Distribuído: os dados de entrada e as características da bacia variam no espaço. Estas informações podem ser distribuídas em sub-bacias ou em malhas.

- Modelo Simplificado: utiliza algoritmos deliberadamente simplificados ou usa grandes incrementos de tempo, para minimizar o esforço computacional.

Segundo [84], previsão é a estimativa de condições em um tempo específico futuro ou durante um determinado intervalo de tempo. Ela é diferente de predição, que realiza a estimativa de condições futuras em função de um tempo de recorrência. São exemplos de previsão, prever o nível ou a vazão de um rio em um determinado período de tempo. Enquanto isso, podemos chamar de predição a estimativa da cheia de 100 anos de tempo de retorno de um determinado rio.

A chuva é um elemento do ciclo hidrológico, e sua grande variabilidade espacial e temporal faz com que seja difícil fazer sua previsão. A medida de chuva geralmente é feita pontualmente e os métodos para esta previsão dependem da aplicação e das escalas de tempo e espaço de interesse. Em aplicações hidrológicas grandes escalas temporais estão associadas a grandes escalas espaciais.

A previsão de vazão é a estimativa futura dos valores de vazão para um determinado período de tempo. A previsão é classificada levando em conta o intervalo de tempo futuro em previsão de curto e longo prazo.

Os modelos de transformação chuva-vazão têm por objetivo estimar o deflúvio em um sistema de drenagem qualquer, gerado por um evento de chuva. Buscam reproduzir as fases do ciclo hidrológico entre a precipitação e o escoamento no ponto de interesse. Os principais usos para os modelos chuva-vazão são o estudo do comportamento dos fenômenos hidrológicos, análise de consistência, preenchimento de falhas, previsão de vazão, previsão de cenários de planejamento e estudo dos efeitos resultantes da modificação do uso do solo [17]. Além disso, observa-se o uso destes modelos em previsão de níveis, estudo do efeito de mudança climática, extensão de séries e criação de séries sintéticas.

Existe uma enorme variedade de tipos de modelos. Desde modelos bastante simplificados, como o Método Racional, muito utilizado em projetos de drenagem para estimativas de vazão em pequenas bacias, até modelos com entradas distribuídas, que consideram a variabilidade espacial e temporal do evento chuvoso. Geralmente estes últimos modelos tentam representar a variação das características da bacia hidrográfica no espaço, e fazem balanços hídricos localizados, determinando parcelas de evapotranspiração, infiltração, escoamento superficial e subsuperficial para cada unidade em estudo. A necessidade de um

levantamento exaustivo de dados é uma das maiores limitações à utilização de modelos mais complexos, o que leva à indagação de qual o aumento de precisão no resultado final que esta prática propicia.

Em razão disso, os modelos chuva-vazão empíricos com Redes Neurais Artificiais vêm sendo muito utilizados com interesse apenas nos resultados, sem buscar o entendimento do funcionamento físico dos processos, enquanto alguns autores vêm aplicando as RNAs justamente para buscar este entendimento.

### ***3.2. REDES NEURAIAS ARTIFICIAIS***

Redes Neurais Artificiais – RNAs são poderosas ferramentas para tratar uma grande diversidade de problemas. Haykin [49] diz que “as RNAs são processadores massivamente paralelos e distribuídos que têm uma propensão natural para armazenar o conhecimento proveniente da experiência e torná-lo útil”.

As RNAs constituem sistemas de processamento que, por serem baseados no funcionamento do sistema nervoso biológico, possuem propensão natural de armazenar conhecimento experimental [49].

Elas foram desenvolvidas inspiradas no processo de comunicação através de impulsos eletroquímicos das células neurais biológicas, sendo constituídas por vários elementos de processamento conectados entre si, onde cada elemento recebe e envia informações de forma semelhante a uma célula neural. Com uma malha muito menor de elementos do que a do cérebro humano, as RNAs são capazes de aprender, executar operações matemáticas, transformações e comparações, descobrir relações ou regras e testar situações de um problema específico [85], características estas que justificam a aplicabilidade desta ferramenta em vários ramos da ciência e tecnologia.

Os primeiros estudos sobre RNAs datam do final do século XIX e início do século XX. Em 1943 o neurofisiologista Warren McCulloch e o matemático Walter Pitts fizeram a primeira analogia entre o comportamento da célula neural viva e os processos eletrônicos. Este trabalho consistia num modelo de resistores variáveis e amplificadores representando conexões sinápticas de um neurônio. Um pouco depois, em 1949, o psicólogo Donald Hebb descobriu a base de aprendizado das RNAs, quando explicou o que ocorre, em nível celular, durante o processo de aprendizado no cérebro. Hebb propôs a utilização de pesos como uma forma

representativa das RNAs assimilarem o conhecimento. A introdução da ideia de pesos como forma de aprendizado das RNAs permitiu que Marvin Minsky, em 1951, construísse o primeiro neurocomputador, Snark, ainda que sem nenhuma aplicação prática [86].

No final da década de 50, Frank Rosenblatt, considerado o pai da neurocomputação, concebeu a primeira RNA nos mesmos moldes dos modelos utilizados hoje. A RNA de Rosenblatt, denominada de *Perceptron*, é uma RNA de uma camada com a capacidade de apreender e identificar padrões conforme as regras propostas por Hebb [49].

Em 1960, Widrow e Hoff, utilizando conceitos de filtragem adaptativa em conjunto com o algoritmo de mínimos quadrados (*least mean-square* – LMS) formularam a RNA Adaline (*Adaptive Linear Element*) [49].

Em 1969, Marvin Minsky e Seymour Papert, publicaram o livro "PERCEPTRON", no qual resumiram e criticaram seriamente a pesquisa sobre as RNAs, alegando que, além de utilizar processos de aproximação empíricos, não realizavam algumas operações booleanas simples (por exemplo, calcular a tabela verdade da operação ou exclusivo). O impacto desta publicação foi significativo, reduzindo o investimento e programas de pesquisa para essa tecnologia [49].

Novos interesses sobre RNAs surgiram novamente em 1974 com Paul Werbos, que lançou as bases do algoritmo de treinamento *backpropagation* (retropropagação) que, mais tarde, em 1986, seria apresentado por Rummelhart, Hinton e Williams. No mesmo ano, o livro "*Parallel Distributed Processing: Explorations in the Microstructures of Cognition*", escrito por Rummelhart e McClelland, foi publicado se tornando mais tarde o livro de maior influência no uso do método de aprendizado de *backpropagation* [49].

Segundo [23], além de considerarem as não linearidades presentes entre as entradas e as saídas, as RNAs possuem as seguintes características:

- Não requerem, a priori, informações sobre o modelo, pois aprendem a partir de exemplos e, assim, capturam relações funcionais entre os dados mesmo se tais relações não sejam diretamente identificáveis. Para que uma RNA possa aprender e garantir um bom desempenho no resultado, o conjunto de dados disponíveis deve ser suficientemente diverso. Nesse sentido, esses modelos podem ser tratados como um método estatístico multivariado não-paramétrico e não linear.

- Têm a capacidade de generalizar. Após a fase de aprendizagem, quando já possuem algum conhecimento sobre as características do conjunto de dados, as RNAs conseguem inferir na população restante mesmo se os dados amostrais contêm ruído nas informações.
- As MLP's são aproximadores universais, isto é, podem aproximar uma função contínua, definida sob um domínio compacto, com precisão arbitrária.

O neurônio artificial é o elemento básico que constitui uma RNA, conhecido também por nó, elemento ou unidade de processamento. A Figura 3.2 traz uma ilustração de um neurônio artificial.

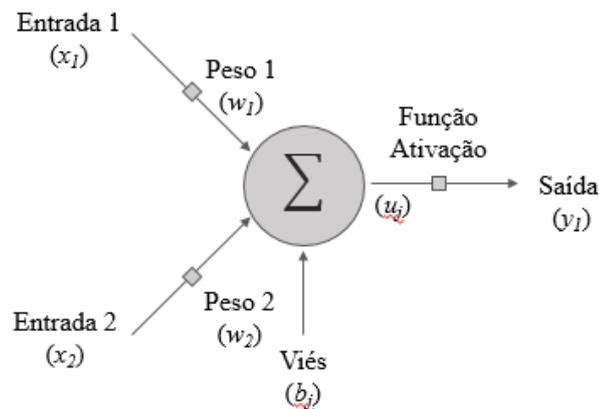


Figura 3.2 – Esquema básico do neurônio artificial. (Adaptado de [49])

Um neurônio artificial é apenas um elemento de uma RNA. Este elemento é idealizado matematicamente de tal forma a simular o mesmo comportamento de uma célula neural biológica, ou seja, o neurônio artificial apresenta estrutura para receber dados, processar estímulos e transmitir uma resposta a outros elementos conectados a este. Basicamente, o neurônio artificial é constituído de três elementos:

- Conjunto de pesos: São os pesos que atribuem à RNA a capacidade de aprendizado. A utilização de pesos simula a forma de entrada de dados em uma célula neural biológica.
- Somatório: esta unidade é responsável pelo estímulo que chega à unidade de processamento, ou seja, a soma das correntes eletroquímicas. No neurônio artificial o somatório é o resultado do produto dos elementos do vetor de entradas  $X$  pelos pesos  $W$ .

- Função de transferência: é a própria unidade de processamento, que recebe o estímulo, resultado do somatório, e transfere a resposta, obtida pela aplicação do estímulo à função de transferência, aos neurônios adjacentes. No modelo matemático a função de transferência ainda pode limitar a amplitude da saída do neurônio.

O neurônio artificial mostrado na figura 3.2 também inclui a entrada de um elemento externo  $b$ , chamado de bias. Isto significa que a combinação linear da unidade somatório deve ser aumentada em um termo para contemplar o termo  $b$ .

Em termos matemáticos, pode-se descrever um neurônio  $j$  pelo seguinte par de equações 3.1 e 3.2.

$$u_j = \sum_{i=1}^p w_i x_{Ni} \quad (3-1)$$

$$y_{Nj} = \varphi(u_j + b_j) \quad (3-2)$$

Onde,  $x_{Ni}$  e  $w_i$  são, respectivamente, elementos do vetor de entradas  $X$  e de pesos  $W$ ,  $b_j$  é o bias do neurônio  $j$ ,  $\varphi(\cdot)$  é a função de transferência e  $y_{Nj}$  a saída  $N$  do neurônio  $j$  [49].

A função de transferência, denotada por  $\varphi(\cdot)$ , define a saída do neurônio em função do nível de atividade na entrada. A utilização da função de transferência permite às RNAs identificar relações lineares e não lineares entre as variáveis de entrada e saída. As funções de transferência mais utilizadas são mostradas na figura 3.3.

A função Linear (Fig. 3.3a) é geralmente utilizada para tratar a entrada e a saída de dados. A função Rampa (Fig. 3.3b) representa uma função não linear simplificada. Ela é linear entre os limites inferior e superior, e bloqueia os valores de saída superiores ao limite. A função Gaussiana (Fig. 3.3d) é utilizada para o treinamento de uma rede de função de base radial (RBF — *Radial Basis Function*).

As funções sigmóide (Fig. 3.3e e 3.3f), caracterizadas pelo seu formato em S alongado, são funções não-lineares, contínuas, monotonicamente crescentes e limitadas por assíntotas horizontais [87]. É possível definir várias funções sigmóides. Estas funções são utilizadas em diversos modelos. A função sigmóide ou logística é a função de ativação ou de transferência mais utilizada em RNAs [88]. As funções sigmóide e tangente hiperbólica são deriváveis em

toda sua extensão, são simétricas e possuem todas as derivadas contínuas, características importantes para os algoritmos *backpropagation* correntemente utilizados para treinamento de RNAs.

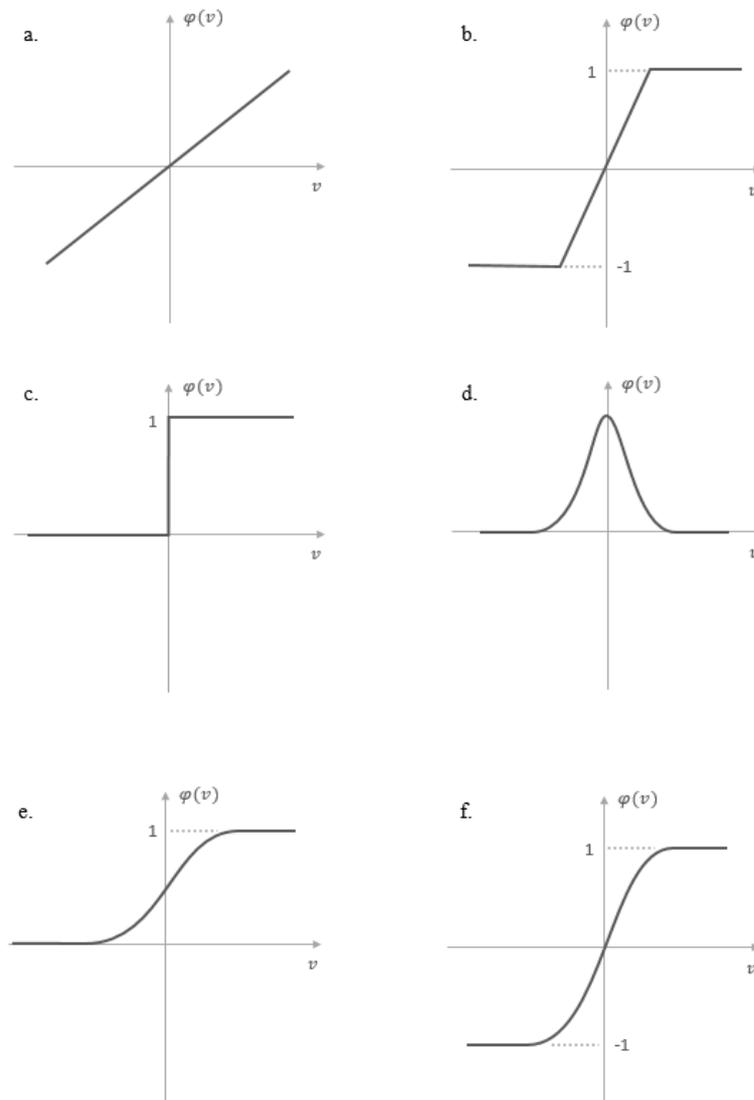


Figura 3.3 –Funções de Transferência. (Adaptado de [85])

Muitas vezes as funções de transferência possuem características restritivas. Isto significa que podem não produzir efeito em um neurônio seguinte quando o estímulo for abaixo de um valor mínimo. As funções rampa e degrau possuem ações restritivas para valores extremos; ultrapassado certo limite, a função dispara o valor 0, 1 ou -1. Pode-se fazer uma analogia com o sistema hidrológico, onde  $\varphi(.) = 1$  corresponde ao escoamento completo da precipitação,  $\varphi(.) = 0$  equivale a infiltração completa e  $0 < \varphi(.) < 1$  corresponde a situação

não extremas [41]. A função sigmóide produz um valor próximo a 0 somente quando o estímulo for um grande valor negativo, e produz uma saída próxima a 1 quando a ativação tiver um grande valor positivo. Essa função faz a transição entre os extremos de forma suave [85].

As Redes Neurais Artificiais aprendem com seu ambiente e melhoram seu desempenho. A solução de problemas por meio de RNAs passa, obrigatoriamente, pela fase de aprendizagem onde a rede extrai informações relevantes de padrões de informação apresentados, gerando uma representação própria do problema. Isso ocorre por meio de um processo iterativo de ajustes aplicado a seus pesos, conhecido como treinamento ou aprendizado.

O aprendizado ocorre quando a rede obtém uma solução generalizada para uma classe de problemas. Esta generalização é obtida por meio de um conjunto de regras bem definidas para a solução de um problema, onde a rede assimila uma determinada função. Estas regras são denominadas de algoritmo de aprendizado ou de treinamento. Existem muitos tipos de algoritmos de treinamento específicos para determinados modelos de Redes Neurais, cada qual com suas vantagens e desvantagens. Esses algoritmos basicamente diferem entre si no ajuste dos pesos.

Uma definição geral de aprendizado no contexto de RNA pode ser expressa da seguinte forma [49]:

"Aprendizagem é o processo pelo qual os parâmetros de uma rede neural são ajustados por meio de um estímulo contínuo do ambiente no qual a rede está operando, sendo o tipo específico de aprendizagem realizada definido pela maneira particular como ocorrem os ajustes realizados nos parâmetros."

Diversos métodos de treinamento de Redes Neurais foram desenvolvidos, podendo ser agrupados em métodos de aprendizado. O aprendizado é classificado de acordo com seu ambiente de funcionamento. Nesse contexto existem os seguintes processos de aprendizado: Supervisionado, Não Supervisionado, Por Reforço e Por Competição. Algumas regras de aprendizado são: correção de erros, aprendizado Hebbiano, aprendizado de Boltzmann e modelo de Kohonen [49], [88]. Visto que este trabalho tem por objetivo o desenvolvimento de RNAs utilizando aprendizado supervisionado, somente este tipo de algoritmo será discutido.

No aprendizado supervisionado, um agente externo é utilizado para treinar a RNA, similar a um professor que indica a resposta desejada para o padrão de entrada. Esta interação

tem por objetivo ajustar os parâmetros da rede de maneira que a rede encontre uma relação entre os pares de entrada-saída. A figura 3.4 ilustra o mecanismo de aprendizado supervisionado. A rede deve possuir pares de entrada e saída, ou seja, um conjunto de padrões entrada/saída. Para cada entrada verifica-se a saída obtida, gerada a partir dos cálculos com os pesos que a rede possui, comparando-a com a saída desejada. O erro verificado é então repassado para o algoritmo de aprendizado, que atualiza os pesos da rede até que o conhecimento sobre o problema seja armazenado no conjunto de pesos. Esse processo iterativo com o conjunto de entrada/saída prossegue até que algum critério de parada seja atendido, por exemplo, a taxa de acerto seja satisfatória.

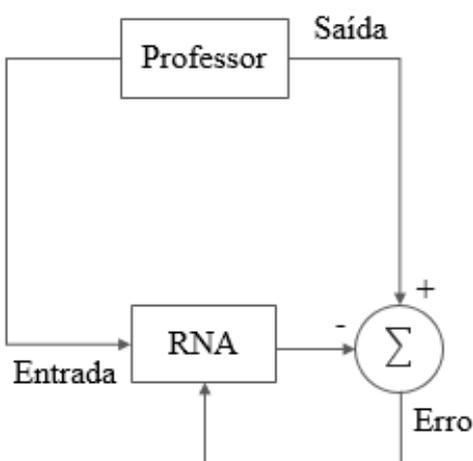


Figura 3.4 –Aprendizado supervisionado. (Adaptado de [49])

O aprendizado supervisionado depende do professor, sem o qual novas estratégias e situações não são assimiladas. A regra delta e o algoritmo *backpropagation* são os algoritmos mais utilizados no treinamento supervisionado de redes múltiplas camadas [88].

Há duas formas de aprendizado supervisionado:

- *Off-line*: Quando os dados do conjunto de treinamento não mudam. Uma vez obtida uma solução, esta deve permanecer fixa. Caso novos dados sejam acrescentados no conjunto de treinamento, um novo treinamento deve ser feito.
- *On-line*: Quando o conjunto de dados está em constante mudança, e a rede permanece em contínuo processo de adaptação.

Uma RNA é a combinação de diversos neurônios sendo *Perceptron* o modelo de RNA mais simples. Proposta inicialmente por Roseblatt no final da década de 50, a RNA do tipo Perceptron é constituída por vários elementos de entrada conectados aos neurônios de uma única camada de saída (figura 3.5). A função de transferência utilizada por estas RNAs limita a saída da RNA aos valores -1 ou 1. Entre as conexões são introduzidos pesos os quais simulam o conhecimento da RNA sobre um problema proposto. As RNAs do tipo Perceptron são aplicadas, principalmente, na classificação de dados e identificação de padrões. Estas RNAs só podem ser aplicadas a problemas linearmente separáveis [26].

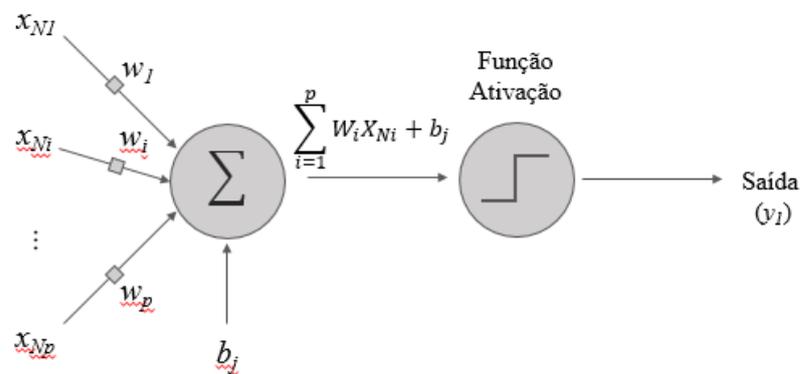


Figura 3.5 – RNA do tipo *Perceptron*. (Adaptado de [49])

As RNAs do tipo *Perceptron* podem ser treinadas através do método supervisionado. O algoritmo de treinamento do *Perceptron* sugerido por Widrow e Hoff, também conhecido como regra delta, constitui um dos mais simples, juntamente com o algoritmo do *Perceptron* [26].

As limitações do *Perceptron* de camada única foram superadas pelo *Perceptron Multicamadas* ou *Multilayers Perceptron* — MLP, atualmente a forma mais popular de RNA, proposta por inicialmente por Rumelhart [26]. Estas RNAs também são conhecidas por RNA *feedforward*.

As RNAs do tipo MLP são formadas por um conjunto de neurônios dispostos em camadas, uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída. Cada um dos neurônios da camada de entrada está conectado a todos os neurônios da camada intermediária. Da mesma forma, cada neurônio da camada intermediária está conectado com todos os neurônios da próxima camada. Caso o modelo tenha uma única camada intermediária, a próxima camada é a de saída. Não há conexões diretas entre a camada de entrada e a camada

de saída. Entre todas as conexões são introduzidos pesos que, semelhante à RNA do tipo *Perceptron* de camada única, são incorporados para representar o conhecimento da RNA sobre o problema proposto. Os pesos são ajustados durante um processo de treinamento. O processo de treinamento tem o objetivo de minimizar os erros na saída da RNA. As RNA do tipo MLP são treinadas de maneira supervisionada [49].

Dentro da RNA do tipo MLP o fluxo de dados se dá em uma única direção, *feedforward*, ou seja, os dados de entrada propagam-se através da RNA, camada a camada, no sentido progressivo. As entradas da primeira camada são multiplicadas pelos pesos das respectivas conexões. Cada neurônio da camada intermediária recebe uma combinação linear dos elementos de entrada. Esta combinação gera um estímulo na função de transferência que emite uma resposta. Ao contrário das RNAs *Perceptron* simples, onde a resposta da função de transferência é considerada a resposta da RNA, na RNA do tipo MLP a resposta da função de transferência é a entrada para a próxima camada esta, por sua vez, pode ser mais uma camada intermediária ou a camada de saída. A entrada da camada de saída é a combinação linear das saídas da última camada intermediária e a saída da última camada é a resposta da RNA do tipo MLP.

O problema de ajuste dos pesos de uma RNA pode ser fundamentado como um problema de otimização. Este tipo de problema é caracterizado por uma função objetivo e um conjunto de restrições de igualdade (equações) ou desigualdade (inequações). A função objetivo pode ser da forma linear, não linear monovariável e não linear multivariável. As funções lineares e aquelas não lineares monovariáveis são representadas por linhas e curvas no plano (figura 3.6a). As funções multivariáveis são representadas por superfícies em três e mais dimensões dependendo do número de variáveis independentes (figura 3.6b). Se o número de variáveis independentes for igual a dois então a superfície da função objetivo será representada em três dimensões, caso contrário, uma superfície com mais de três dimensões é necessária, o que não pode ser representado graficamente.

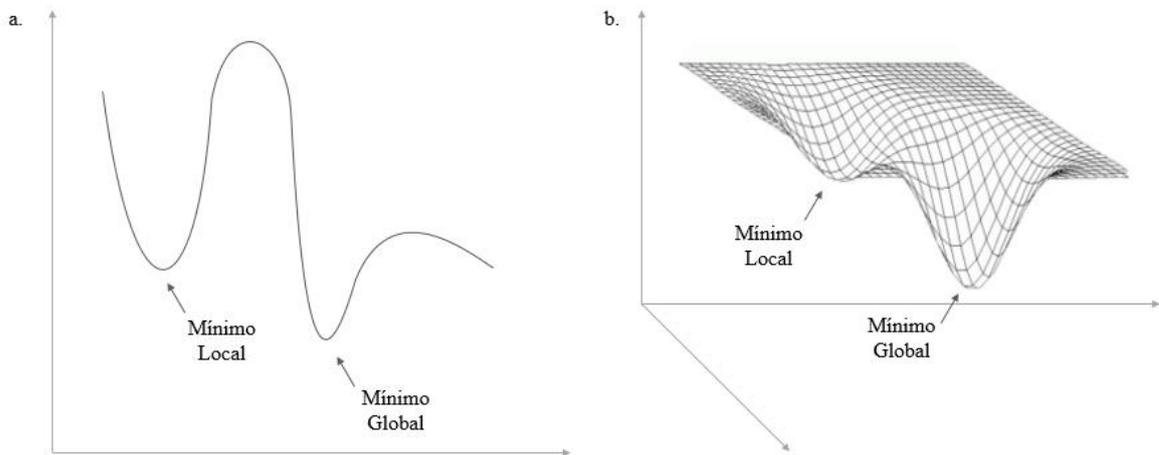


Figura 3.6 – Representação gráfica de um problema de otimização. (Adaptado de [49])

Um problema de regressão que utiliza o método dos mínimos quadrados para ajustar os parâmetros de um determinado modelo matemático pode ser formulado da seguinte forma:

$$\min_{\underline{w}} E_s(\underline{w}) = \sum_{k=1}^N e_k^2 \quad (3-3)$$

Onde  $E_s$  é a função objetivo,  $e_k$  o erro dado por  $e_k = d_k - y_k$ ,  $d_k$  a saída desejada e  $y_k$  é a saída da função  $f(\underline{w}, \underline{x}_k)$ , com  $\underline{w}$  representando o conjunto de pesos da RNA e  $\underline{x}_k$  o conjunto de variáveis explicativas para o  $k$ -ésimo padrão.

No problema, o método de otimização ajustará os coeficientes das variáveis independentes da função  $f(\underline{w}, \underline{x})$ , ou seja, o conjunto de pesos  $\underline{w}$ . Se existir uma única variável independente, a solução do problema estará num plano. Se existirem duas variáveis a solução estará no mínimo global da superfície representada no espaço 3D. Se existirem mais de duas variáveis a solução se encontrará no mínimo global de uma hipersuperfície.

Para solução de problemas de otimização não lineares podem-se utilizar técnicas como descida em gradiente e o método de Newton-Rapshon. Estes métodos numéricos fazem uso de um processo iterativo para obtenção da solução do problema, podendo ser resumidos pela expressão:

$$\underline{w}_{n+1} = \underline{w}_n + \underline{\Delta w}_n \quad (3-4)$$

Pelo método de descida em gradiente escolhe-se um vetor inicial  $\underline{w}_0$  e, em seguida, determinam-se os vetores  $\underline{w}_1, \underline{w}_2, \underline{w}_3$ , em diante até a convergência pela relação recorrente (3-4):

$$\underline{w}_{n+1} = \underline{w}_n - \eta \nabla E_s |_{w_n} \quad (3-5)$$

Onde  $\underline{w}_{n+1}$  é o vetor dos pesos na iteração  $(n + 1)$ ,  $\underline{w}_n$  o vetor dos pesos na iteração  $(n)$  e  $\underline{\Delta w}_n = -\nabla E_s |_{w_n}$ , sendo  $\nabla E_s |_{w_n}$  o gradiente de  $E_s(\underline{w})$  calculado em  $\underline{w}_n$  e  $\eta$  um escalar positivo. O uso do sinal negativo indica a descida do gradiente na superfície de erro. O processo iterativo termina quando, por exemplo, a diferença entre os valores da função objetivo para dois conjuntos  $\underline{w}$  sucessivos, for menor que uma tolerância pré-estabelecida. O último conjunto  $\underline{w}$  computado torna-se a aproximação final de  $\underline{w}$ .

Pelo método de Newton-Raphson escolhe-se um vetor inicial  $\underline{w}_0$  da mesma forma que no método de descida em gradiente e determinam-se os vetores  $\underline{w}_1, \underline{w}_2, \underline{w}_3$ , em diante até a convergência recursivamente por intermédio de (3-5):

$$\underline{w}_{n+1} = \underline{w}_{n+1} - (H_{E_s} |_{w_n})^{-1} \nabla E_s |_{w_n} \quad (3-6)$$

Onde  $\underline{\Delta w}_n = -(H_{E_s} |_{w_n})^{-1} \nabla E_s |_{w_n}$  sendo  $H_{E_s} |_{w_n}$  matriz hessiana de  $E_s(\underline{w})$  calculada em  $\underline{w}_n$ .

No método Newton-Raphson a regra de parada pode ser a mesma do método de descida em gradiente, existindo também outros critérios de parada, como por exemplo, obtenção de valor de  $E_s$  inferior a uma tolerância especificada ou número máximo de iterações.

Se  $\underline{w}_0$  não for escolhido corretamente, o método poderá convergir para um mínimo local ou não convergir de forma alguma. Em qualquer dos casos o processo é interrompido e recomeça a partir de uma nova condição inicial.

Pode-se abordar o problema de ajustes dos pesos de uma RNA do tipo MLP da mesma forma que um problema de ajuste de curva, ou seja, incorporar um modelo de otimização na solução do problema.

Supondo a função objetivo da mesma forma que a equação (3-3) tem-se (3-6)

$$\min_{\underline{w}} E_s(\underline{w}) = \frac{1}{N} \sum_{k=1}^N [d_k - f(\underline{w}, \underline{x}_k)]^2 \quad (3-7)$$

Para solução deste problema podem-se utilizar diversas técnicas consagradas como o algoritmo *backpropagation*, que se confunde com o gradiente descendente, gradiente descendente com termo momentum, gradiente em cascata, métodos quasi-Newton e *Levenberg-Maquardt* [62].

Em recursos hídricos, as técnicas mais utilizadas são o algoritmo *backpropagation* ou gradiente descendente e o algoritmo *Levenberg-Maquardt* [41].

Cabe ressaltar que nem todas as RNAs possuem uma função objetivo na forma da equação (3-6). A referência [24] cita que a função objetivo pode ser, por exemplo, a média do erro quadrático e que utilizar funções objetivo diferentes levam os pesos à ajustes diferentes.

O algoritmo *backpropagation* de ajuste dos pesos de uma RNA do tipo MLP foi apresentado pela primeira vez por Paul Werbos e popularizado por [48]. A classificação mais geral que pode ser dada ao algoritmo *backpropagation* é a de um método de otimização. Na verdade, o algoritmo *backpropagation* é, em parte, uma adaptação dos métodos de otimização convencionais que leva em consideração a distribuição da RNA em camadas. O algoritmo de retropropagação do erro é um algoritmo supervisionado, visto que necessita de um conjunto de saídas desejadas para estimação dos parâmetros do modelo através da correção do erro gerado para cada saída.

Dado um conjunto  $D$  contendo  $N$  pares entrada-saída,  $D = \{\underline{x}_k, d_k\}$ ,  $k = 1, 2, \dots, N$ ,  $\underline{x}_k = [x_{k1}, x_{k2}, \dots, x_{kn}]^t$ ,  $\underline{d}_k = [d_{k1}, d_{k2}, \dots, d_{kn}]^t$ , o objetivo deste algoritmo consiste na estimação do vetor de parâmetros  $\underline{w}$  que minimize o erro médio quadrático para este conjunto de dados, também conhecido como risco empírico, dado pela equação (3-6). Visto que o erro só pode ser obtido diretamente para os neurônios da camada de saída, a ideia do algoritmo reside na propagação deste erro através da rede, fazendo com que o MLP, além de propagar os sinais de entrada para frente, propague os sinais de erro em sentido contrário, objetivando a modificação dos pesos sinápticos e dos bias de forma a minimizar o funcional descrito na equação (3-7). Daí o nome de retropropagação do erro.

Os algoritmos convencionais têm o objetivo de ajustar os coeficientes das variáveis independentes a fim de minimizar a soma do erro, ao quadrado, entre a saída do modelo e a saída desejada. Quando aplicados para estimação dos parâmetros de um modelo de regressão linear múltipla, por exemplo, cada parâmetro do modelo está diretamente correlacionado com a saída do modelo. Neste caso todas as variáveis independentes, em princípio, têm contribuição direta sobre o erro.

No caso das RNAs de múltiplas camadas, os pesos entre a camada de entrada e a primeira camada intermediária estão diretamente relacionados com as variáveis de entrada. Já os pesos das camadas seguintes estão relacionados com as variáveis modificadas por combinações lineares e pelas funções de transferência. Neste caso nem todos os pesos têm a mesma contribuição sobre o erro na saída da RNA.

O algoritmo *backpropagation* leva em consideração esta característica das RNAs e corrige o peso entre cada conexão de forma proporcional ao erro que este esteja causando na saída da RNA. Apesar desta ser a principal característica deste algoritmo, o termo *backpropagation* é usado para caracterizar outras situações. Por exemplo, devido à grande popularidade as RNAs do tipo MLP são muitas vezes ditas como sendo uma RNA *backpropagation*. Este termo também é usado para caracterizar o treinamento das RNAs MLP [89]. Matematicamente o que este algoritmo faz é fornecer um método eficiente para obter as primeiras derivadas da função objetivo em relação aos pesos e bias da mesma.

Na forma mais clássica do algoritmo *backpropagation* os pesos das conexões da RNA são ajustados proporcionalmente à primeira derivada. Este método de ajuste é conhecido por gradiente descendente, baseado na equação (3-5). O valor de  $\eta$  é determinado inicialmente e pode ser atualizado ao longo do processo iterativo [89]. Um valor baixo para  $\eta$  significa um processo de otimização mais lento. Quando os valores de  $\eta$  são altos a convergência para uma solução também pode ser alta, no entanto há o risco de ultrapassar o ponto mínimo.

### 3.2.1. Algoritmo Levenberg-Marquardt

Da mesma forma que o método do gradiente descendente é a base do algoritmo *backpropagation*, cuja principal contribuição foi estabelecer um procedimento para cálculo das primeiras derivadas da função objetivo, o algoritmo *Levenberg-Marquardt* é uma aproximação do método de *Newton-Raphson*, utilizando o princípio do algoritmo *backpropagation* na determinação das primeiras derivadas desta mesma função.

O método de *Levenberg-Marquardt* utiliza uma aproximação da matriz hessiana  $\underline{\underline{H}}(\underline{w})$  tomando por base informações do gradiente e do erro para cada padrão, assim como os métodos quasi-newton, que como o próprio nome já diz, utilizam a ideia básica do método de Newton. Considerando o método numérico para atualização dos pesos dado em (3-4), o algoritmo *Levenberg-Marquardt* utiliza o passo de atualização dos pesos  $\underline{\Delta w}_n$  dado por [49]:

$$\underline{\Delta w}_n = [\underline{\underline{H}}(\underline{w}) + \lambda \underline{I}]^{-1} \nabla E_S(\underline{w}) \quad (3-8)$$

onde  $\lambda$  é um parâmetro que garante que  $[\underline{\underline{H}}(\underline{w}) + \lambda \underline{I}]$  é definida positiva e  $\underline{\underline{H}}(\underline{w})$  é a matriz hessiana de  $E_S(\underline{w})$  dada por:

$$\underline{\underline{H}}_S(\underline{w}) = \begin{bmatrix} \frac{\partial^2}{\partial w_1^2} E_S(\underline{w}) & \cdots & \frac{\partial^2}{\partial w_1 \partial w_M} E_S(\underline{w}) \\ \vdots & \ddots & \vdots \\ \frac{\partial^2}{\partial w_M \partial w_1} E_S(\underline{w}) & \cdots & \frac{\partial^2}{\partial w_M^2} E_S(\underline{w}) \end{bmatrix} \quad (3-9)$$

Desta forma, o algoritmo de *Levenberg-Marquardt* pode ser considerado como um algoritmo de otimização em regiões viáveis, visto que limita a busca apenas em regiões no entorno do ponto de operação, onde as aproximações consideradas pelo método são válidas [90]. Na prática, o valor da constante  $\lambda$  deve ser modificado ao longo do processo de otimização. Uma forma de atualização bastante utilizada consiste em fazer  $\lambda = 0,1$  no início do processo iterativo, e, se o erro diminuir para a iteração  $n$ , diminuir  $\lambda$  em uma ordem de grandeza, ou seja,  $\lambda(n+1) = 0,1\lambda(n)$ . Em caso contrário, aumentar em uma ordem de grandeza, ou seja,  $\lambda(n+1) = 10\lambda(n)$  [49].

### 3.2.2. Algoritmo de Treinamento Bayesiano

A inferência Bayesiana, que recebe este nome por ser baseada no teorema de Bayes, tem como objetivo calcular a probabilidade a posteriori de uma determinada variável aleatória a partir da combinação entre o conhecimento prévio e a evidência existente nos dados disponíveis. Este conceito, quando aplicado ao problema de treinamento de Redes Neurais, origina o chamado treinamento ou regularização Bayesiana.

A aplicação de inferência bayesiana ao desenvolvimento de MLPs foi proposta originalmente por *David J.C. Mackay* em 1992 [91]. As principais vantagens desta abordagem são as seguintes [90]:

- O algoritmo de retropropagação do erro tradicional pode ser visto como um caso particular dos resultados obtidos através da aplicação de técnicas de inferência bayesiana.
- A teoria da regularização apresenta uma interpretação natural dentro desta abordagem. Um dos motivos reside na obrigatoriedade de inserção de algum conhecimento prévio sobre o problema para obtenção da solução, característica marcante tanto das técnicas de inferência bayesianas quanto da teoria de regularização de Tikhonov.
- Para problemas de regressão, intervalos de confiança podem ser gerados automaticamente.
- Este método fornece uma estimativa automática do parâmetro de regularização  $\lambda$ , o qual é atualizado ao longo do algoritmo de treinamento, sem a necessidade de técnicas de re-amostragem ou de qualificação analítica de modelos para estimativa deste parâmetro.
- Este procedimento permite o desenvolvimento de um algoritmo de determinação automática de relevância das entradas, do inglês *automatic relevance determination* (ARD), técnica que pode ser utilizada para seleção de variáveis de entrada de modelos neurais.
- Através do cálculo da evidência de cada modelo, relacionada com a probabilidade a posteriori de cada estrutura, esta metodologia permite a comparação entre diferentes modelos utilizando somente os dados disponíveis para treinamento.
- Técnicas de inferência bayesiana permitem afirmar em qual região do espaço de entrada devem ser obtidos novos dados com o intuito de aumentar a informação contida no modelo, característica conhecida como aprendizado ativo.

Visto que esta dissertação utilizará o treinamento bayesiano para problemas de aproximação funcional, utilizando MLPs com uma única camada escondida e uma única saída linear, a discussão sobre este assunto estará restrita à apresentação deste algoritmo para este tipo de modelo. Maiores detalhes sobre a aplicação de técnicas bayesianas ao treinamento de MLPs podem ser encontrados em [90], [91].

Definida a estrutura a ser utilizada, ou seja, número de camadas ocultas, número de neurônios por camada e tipo de função de ativação de cada neurônio, dado o conjunto  $D = \{X, Y\}$ ,  $X = \{\underline{x}_1, \dots, \underline{x}_n\}$ ,  $Y = \{d_1, \dots, d_n\}$ ,  $\underline{x} \in \mathbb{R}^n$ ,  $\underline{x} = [x_1, \dots, x_n]^t$ ,  $d \in \mathbb{R}$ ,  $d = F(\underline{x}) + \zeta$ , o objetivo do treinamento do modelo, sob o ponto de vista da inferência bayesiana, reside na

determinação do vetor de parâmetros  $\underline{w} \in \mathbb{R}^M$  que maximize a probabilidade *a posteriori*  $p(\underline{w}|Y, X)$ , dada por [92]:

$$p(\underline{w}|Y, X) = \frac{p(Y|\underline{w}, X)p(\underline{w}|X)}{p(Y|X)} \quad (3-10)$$

Na equação (3-13),  $p(Y|X) = \int p(Y|\underline{w}, X)p(\underline{w}|X)d\underline{w}$  é um fator de normalização, que garante que  $\int p(\underline{w}|Y, X)d\underline{w} = 1$ .

Portanto, para o cálculo da probabilidade *a posteriori*  $p(\underline{w}|Y)$  do vetor  $\underline{w}$ , é necessário o conhecimento da distribuição de probabilidade *a priori*  $p(\underline{w})$  deste vetor, como também a sua função de verossimilhança  $p(Y|\underline{w})$ , a qual está relacionada com a distribuição de probabilidade do ruído existente na saída desejada. Na ausência de conhecimento prévio sobre a solução, conforme é o caso do treinamento de MLPs, a escolha da distribuição  $p(\underline{w})$  deve refletir tal falta de conhecimento. Visto que modelos apresentando componentes de  $w$  com pequena magnitude reproduzem mapeamentos suaves [50], uma escolha razoável para a distribuição  $p(\underline{w})$  reside na distribuição *gaussiana* com vetor média nulo e matriz de covariância  $\alpha^{-1}\underline{I}$ ,  $\underline{I} \in \mathbb{R}^M \times \mathbb{R}^M$  igual à matriz identidade, dada por:

$$p(\underline{w}) = \frac{1}{Z_{\underline{w}}(\alpha)} e^{-\left(\frac{\alpha}{2}\|\underline{w}\|^2\right)} \quad (3-11)$$

$$Z_{\underline{w}}(\alpha) = \left(\frac{2\pi}{\alpha}\right)^{\frac{M}{2}} \quad (3-12)$$

Na equação (3-15),  $\alpha \in \mathbb{R}^+$  é um dos chamados hiperparâmetros.

Definida a distribuição  $p(\underline{w})$ , resta agora especificar a distribuição de probabilidade do ruído  $\zeta$  existente na saída desejada. Supondo que a função a ser aproximada  $F(\underline{x})$  apresente certo grau de suavidade, e que o ruído  $\zeta$  possui distribuição gaussiana com média nula e variância  $\beta^{-1}$ , a probabilidade da ocorrência de uma saída específica  $d_k$ , dado o vetor de entrada  $\underline{x}_k$  e o vetor de parâmetros  $\underline{w}$ , é dada pela expressão (3-16) [92].

$$p(d_k | \underline{x}_k, \underline{w}) = \frac{e^{\{-\frac{\beta}{2}[d_k - f(\underline{x}_k, \underline{w})]^2\}}}{\int e^{\{-\frac{\beta}{2}[d_k - f(\underline{x}_k, \underline{w})]^2\}} dd_k} \quad (3-13)$$

Partindo do pressuposto que os padrões do conjunto de treinamento foram obtidos de maneira independente a partir desta distribuição, podemos obter uma expressão para a verossimilhança  $p(Y|\underline{w})$ , dada pela equação (3-17).

$$p(Y|\underline{w}) = \frac{1}{z_y(\beta)} e^{\{-\frac{\beta}{2}\sum_{k=1}^n [d_k - f(\underline{x}_k, \underline{w})]^2\}} \quad (3-14)$$

$$z_y(\beta) = \left(\frac{2\pi}{\beta}\right)^{\frac{N}{2}}$$

Da mesma forma que  $\alpha$  (3-15), na equação (3-17),  $\beta \in \mathbb{R}^+$  é outro hiperparâmetro.

Assim, conforme [92], o algoritmo de treinamento bayesiano de MLP's pode ser resumido da forma que segue:

1. Faça  $l = 0$ .
2. Inicialize o vetor de parâmetros  $\underline{w}(l)$  e os hiperparâmetros  $\alpha(l)$  e  $\beta(l)$ .
3. Utilizando alguma técnica de otimização, atualize o vetor de parâmetros  $\underline{w}(l + 1)$  através da minimização do funcional  $S(\underline{w})$ .
4. Se o critério de parada for atendido, encerre o algoritmo. Do contrário, vá para o passo 5.
5. Calcule a matriz *hessiana*  $\underline{\underline{H}}(\underline{w}) \Big|_{\underline{w}=\underline{w}(l)}$ .
6. Atualize os hiperparâmetros  $\alpha_i(l + 1)$  e  $\beta(l + 1)$ .
7. Faça  $l = l + 1$  e retorne ao passo 3

Um algoritmo completo para cálculo da matriz *hessiana* para MLPs pode ser encontrado em [93].

### 3.2.3. Precauções para uma RNA do tipo MLP

Além dos modelos de otimização e da função objetivo citados anteriormente, há outros elementos que influenciam no funcionamento de uma RNA e que devem ser avaliados para melhorar o seu desempenho. A seguir são apresentados os cuidados que devem ser considerados para melhorar a resposta de uma RNA.

#### 3.2.3.1. Arquitetura

Uma diferença importante entre as RNAs e os métodos estatísticos é a determinação da forma funcional  $f(\overline{x_n}, W)$  [50], ou seja, a determinação da arquitetura da RNA. Definir uma arquitetura para uma RNA consiste em determinar o número de camadas e o número de neurônios em cada camada. As referências [49], [50], [89] afirmam que para determinar a solução de qualquer problema de aproximação de uma função à um conjunto de dados é suficiente uma RNA com três camadas. Neste caso, definir a arquitetura de uma RNA se limita a determinar o número de entradas e o número de neurônios na camada intermediária.

O número de saídas é consequência do problema proposto. Poderia se afirmar que as entradas são função das variáveis disponíveis, no entanto, [25] citam em seu trabalho que as entradas são função também da dimensionalidade do banco de dados disponível. Assim, o número de entradas pode ser tão grande quanto for a disponibilidade de dados.

Há várias heurísticas para definição do número de neurônios na camada intermediária. A maioria dos trabalhos utiliza o conceito de validação cruzada, ou seja, modelos com diferentes números de neurônios na camada oculta são testados para um conjunto independente de dados, sendo selecionado aquele que apresentar melhor desempenho para esta base de dados [56]. A referência [8], por exemplo, considerou RNAs com 3, 5, 8 e 10 neurônios na camada intermediária e avaliou o desempenho destas RNAs em termos de  $R^2$  (correlação entre a saída desejada e a saída estimada) e da raiz do erro quadrático médio (*root mean squared error* – RMSE) para o conjunto de validação. Já em [94] os autores utilizaram o algoritmo de correlação em cascata que a partir de um número inicial de neurônios na camada intermediária agrega neurônios um a um até que se obtenha o desempenho ótimo. A referência [52] também apresenta várias avaliações quanto à arquitetura da RNA. Nesta oportunidade os autores fizeram o teste de RNA com quatro camadas obtendo resultados razoáveis, mas inferiores às RNAs com três camadas.

### 3.2.3.2. Número de épocas

O número de épocas representa o número de atualizações ocorridas nos pesos e bias considerando uma apresentação completa do conjunto entrada/saída. O número de épocas representa os estágios de aprendizado de uma RNA. No início do treinamento os erros são altos e as RNAs são capazes de ajustar apenas funções mais simples. À medida que o número de épocas aumenta, o erro diminui e torna-se possível o mapeamento de funções mais complexas. No entanto, nem sempre aumentar o número de épocas significará um melhor desempenho da RNA no ajuste de funções. No início do processo de treinamento, os pesos rapidamente se ajustam para uma situação genérica; esta situação é representada por uma curva que passa próxima a todos os pontos. A figura 3.8 ilustra este processo.

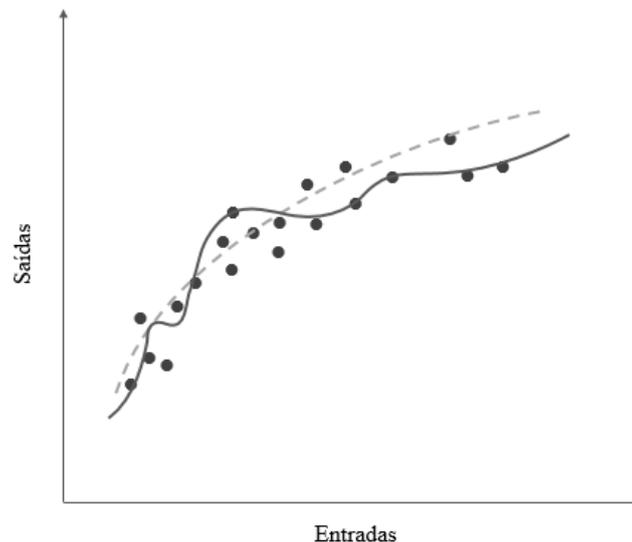


Figura 3.7 – Representação gráfica de um problema de otimização. (Adaptado de [88])

Os pontos em preto representam os dados a que se deseja ajustar uma função  $f(\bar{x}_n, W)$  qualquer; a curva tracejada é o resultado dos primeiros estágios do treinamento, onde a RNA representa o desenvolvimento, a forma gráfica ou a forma genérica da função  $f(\bar{x}_n, W)$ . Com o aumento do número de épocas, a RNA aproxima os pontos genéricos dos pontos particulares tomando a forma da curva cinza inteira na Figura 3.8. Este processo é conhecido por *overfitting*. Neste caso, o erro no processo de treinamento é menor, mas os pesos encontrados não representarão o problema investigado porque a RNA se ajusta ao problema particular da amostra utilizada durante o treinamento.

A investigação sobre o número de épocas ideal durante o treinamento de uma RNA está diretamente ligada à capacidade de generalização da RNA em relação ao problema proposto. Na referência [52] os autores fizeram uma investigação detalhada quanto à avaliação do número de épocas no desempenho das RNAs em recursos hídricos.

Cabe ainda ressaltar que o mesmo efeito do *overfitting* alcançado pelo aumento elevado do número de épocas no treinamento, também, pode ser alcançado pelo número excessivo de neurônios nas camadas intermediárias.

### 3.2.3.3. Inicialização dos pesos

Por definição os pesos das conexões de uma RNA são responsáveis por armazenar o conhecimento da RNA sobre o problema proposto. Matematicamente foi visto que os pesos entre as conexões definem um ponto na superfície da função objetivo. Se os pesos em questão forem os pesos ótimos então o conjunto dos pesos deve representar o ponto de mínimo da mesma superfície. A obtenção deste ponto é garantida quando o problema de otimização for convexo [26], o que não é verdade para o problema de ajuste ótimo de pesos de MLPs sob o critério dos mínimos quadrados.

Em [24] os autores citam que as RNAs do tipo MLP geram superfícies muito irregulares e que o risco em chegar numa solução ótima local é muito alto. Se o ponto inicial estiver próximo a um mínimo local, a solução tenderá a convergir para este ponto. Evitar que a solução do problema recaia num mínimo local está diretamente correlacionada com a escolha dos pesos iniciais. Isto significa que ao avaliar o desempenho de uma RNA em relação aos pesos é necessário alterar algumas vezes os pesos iniciais, ou seja, mudar o ponto inicial na superfície de erro.

Além desta abordagem, é importante dar atenção à escala dos valores dos pesos. As referências [26] e [49] citam que pesos iniciais com valores muito altos tornam a ação das funções de transferência restritivas. Nesta situação os gradientes locais assumem valores pequenos, o que, por sua vez ocasionará uma diminuição da velocidade do processo de aprendizagem. Por outro lado, quando os valores iniciais são muito pequenos, o método de otimização pode operar em uma região muito plana. Os mesmos autores recomendam que os pesos iniciais sejam iniciados aleatoriamente em torno de zero e entre -1 e 1.

#### 3.2.3.4. Normalização

A entrada de dados em um neurônio artificial é a combinação linear de todos os sinais que chegam até este mesmo neurônio. O resultado desta combinação linear é o estímulo para a função de transferência. Com exceção da função linear (figura 3.2a), todas as outras funções apresentam ações restritivas para estímulos extremos, ou seja, no caso mais geral, quando o estímulo é maior que 1 ou menor que -1 as funções respondem com valores 0, 1 e -1. No entanto, na maior parte dos problemas práticos, sejam matemáticos, físicos ou de engenharia, os valores das entradas vão muito além da escala [-1,1].

Isto significa que quando a função de transferência utilizada for diferente da função linear, os valores das entradas devem passar por algum tipo de transformação. Esta transformação de uma escala real para uma escala compatível com a função de transferência utilizada chama-se normalização.

Em recursos hídricos as funções de transferência mais utilizadas são a sigmóide na camada intermediária e linear na camada de saída. Novamente afirma-se que não há uma regra clara sobre qual é o melhor tipo de normalização a ser adotada. Em [95] os autores utilizaram RNA na modelagem do processo chuva mensal e utilizaram a equação (3-18) a seguir na normalização dos dados de entrada:

$$x_{norm} = FMIN + \frac{(x - x_{min})}{(x_{max} - x_{min})} (FMAX - FMIN) \quad (3-15)$$

Onde  $x$  e  $x_{norm}$  representam, respectivamente, a variável a ser normalizada e o seu valor normalizado,  $x_{max}$  e  $x_{min}$  são os valores máximo e mínimo da variável a ser normalizada e  $FMAX$  e  $FMIN$  representam, respectivamente, os valores máximos e mínimos na escala normalizada. No trabalho de [95] foi utilizado  $FMAX = 0,95$  e  $FMIN = 0,05$ . Considerando funções de transferência na camada intermediária do tipo tangente hiperbólica,  $FMAX = 1$  e  $FMIN = -1$ .

### 3.3. PARTICLE SWARM OPTIMIZATION

O método *Particle Swarm Optimization* (PSO), traduzido como Otimização por Enxame de Partículas, demonstrou ser eficaz na otimização de problemas difíceis multidimensionais descontínuos em uma grande variedade de campos [96]. Trata-se de uma técnica evolucionária

estocástica, que tem se mostrado superior a outros métodos de otimização como algoritmos genéticos [97]. O PSO foi desenvolvido em 1995 por Kennedy e Eberhart [98], e apesar de ser classificado como algoritmo evolucionário, onde a força tradicionalmente reside na competição, como em algoritmos genéticos, no PSO a estratégia de evolução utilizada é a colaboração.

O PSO pode ser melhor compreendido através de uma analogia semelhante a que levou ao seu desenvolvimento. Imagine um enxame de abelhas em um campo com o objetivo de encontrar neste campo a localidade com a maior densidade de flores. Sem conhecimento do campo onde se encontram, as abelhas começam suas buscas por flores em locais aleatórios com velocidades aleatórias. Cada abelha pode lembrar os locais em que ela encontrou a maior quantidade de flores, ao mesmo tempo em que tomam conhecimento dos locais onde as outras abelhas encontraram uma abundância de flores. Divididas entre o regresso ao local onde tinham encontrado pessoalmente a maioria das flores, ou a explorar o local relatado pelas outras abelhas de ter a maioria das flores, cada abelha ambivalente acelera em ambas as direções alterando sua trajetória voando para algum lugar entre os dois pontos, influenciadas pela nostalgia ou influência social para sua decisão [99].

Essas ponderações possuem terminologia explícita no PSO, conforme:

- **Partículas ou Agentes:** Cada indivíduo no enxame é chamado de partícula ou agente. Todas as partículas do enxame atuam individualmente sob o mesmo princípio que é acelerar em direção a melhor localização pessoal e melhor localização global, sempre verificando o valor da sua localização atual.
- **Posição:** Na analogia com enxame, a posição é o que se refere ao lugar onde encontra-se cada abelha no campo. Em geral, esta ideia pode ser estendida a um espaço de qualquer dimensão, de acordo com o problema em questão. Este espaço multidimensional é o espaço de solução para o problema a ser otimizado, onde qualquer conjunto de coordenadas representa uma solução para o problema. Na analogia com enxames, a solução é um local físico no espaço tridimensional.
- **Aptidão:** Assim como em todas as técnicas de computação evolutiva, deve existir alguma forma para avaliar quão boa é a posição local de cada partícula. A função de aptidão, ou função objetivo, no caso do PSO, deve tomar a posição no espaço de solução e retornar um único número que representa o valor dessa posição. Na analogia de

enxames a função de adequação seria apenas a densidade de flores, uma vez que quanto maior a densidade melhor é a localização.

- Melhor pessoal - *pbest*: Cada abelha lembra o local onde ela mesma encontrou a maioria das flores. Se este local pessoalmente descoberto por uma abelha tem o maior valor de aptidão, então este é chamado de *pbest*, o melhor local individualmente encontrado. Cada uma das abelhas tem o seu próprio *pbest* determinado pelo caminho que ela voou. Em cada ponto ao longo de seu caminho a abelha compara o valor da aptidão de seu local atual com o *pbest*. Se o local atual tem um valor de aptidão maior, *pbest* é atualizado para a localização atual.
- Melhor Global - *gbest*: Cada abelha também deve de alguma forma conhecer a maior concentração de flores descoberta por todo o enxame. Este local de maior aptidão encontrado é conhecido como o melhor global ou *gbest*. Para o enxame inteiro há uma *gbest* para onde cada abelha é atraída. Em cada ponto ao longo de seu caminho cada abelha compara a adequação de seu local atual com a *gbest*. Se alguma abelha está em um local de maior aptidão em relação ao enxame inteiro, este passa a ser a *gbest*.
- Velocidade máxima: A movimentação de cada partícula é baseada em três parâmetros: fator de sociabilidade, que determina a atração das partículas para a melhor posição descoberta por qualquer partícula do enxame (*gbest*); fator de individualidade, que determina a atração da partícula para sua melhor posição (*pbest*) e a velocidade máxima, que delimita a intensidade do movimento.

O primeiro passo para a implementação do PSO é escolher os parâmetros que precisam ser otimizados e dar-lhes uma gama razoável para a busca da solução ótima. Isto exige a especificação de um valor mínimo e máximo para cada dimensão em uma otimização N-dimensional. Isso é conhecido como  $X_{minn}$  e  $X_{maxn}$ , respectivamente, variando de 1 a N

Em seguida, é necessário definir uma Função Objetivo. Este importante passo prevê a ligação entre o algoritmo de otimização e o mundo físico. É fundamental que a função escolhida represente com precisão, em um único número, quão boa é a solução. A função objetivo deve apresentar uma dependência funcional que é relativa à importância de cada característica a ser otimizada. A função de objetivo e o espaço de soluções devem ser desenvolvidos especificamente para cada otimização; o resto da aplicação, no entanto, é independente do sistema físico que está sendo otimizado.

Para iniciar a pesquisa em busca da melhor posição no espaço de solução, cada partícula começa em sua própria localização ao acaso, com uma velocidade aleatória, tanto em sua direção e magnitude. A sua posição inicial é o único local encontrado por cada partícula sendo o primeiro  $p_{best}$  respectivo para cada partícula. O primeiro  $g_{best}$  é selecionado dentre estas posições iniciais. Cada partícula deve então ser movida através do espaço solução como se fosse uma abelha em um enxame. O algoritmo age em cada partícula, uma por uma, percorrendo o enxame inteiro.

A manipulação da velocidade de uma partícula é o elemento central deste processo de otimização. A velocidade da partícula é alterada de acordo com a posição relativa de  $p_{best}$  e  $g_{best}$ . As partículas são aceleradas nas direções destes locais de maior aptidão de acordo com a seguinte equação:

$$v_{(n+1)} = wv_n + c_1r_1(p_{best} - x_n) + c_2r_2(g_{best} - x_n) \quad (3-16)$$

Onde  $v_n$  é a velocidade da partícula na  $n$ -ésima iteração e  $x_n$  é a partícula com  $N$  coordenadas em uma otimização  $N$ -dimensional. Resulta desta equação, que a nova velocidade é simplesmente a antiga velocidade multiplicada por  $w$  com aumento na direção de  $g_{best}$  e  $p_{best}$  para essa dimensão particular. As constantes  $c_1$  e  $c_2$  estão reduzindo os fatores que determinam a atração entre  $g_{best}$  e  $p_{best}$ . Estas são muitas vezes referidas como as taxas cognitivas e sociais, respectivamente:  $c_1$  é um fator determinante de quanto a partícula é influenciada pela memória de sua melhor localização, e  $c_2$  é um fator determinante de quanto a partícula é influenciada pelo resto do enxame. Aumentar  $c_1$  incentiva a exploração do espaço de soluções que cada partícula se move em direção a sua própria  $p_{best}$ . Por sua vez  $c_2$  estimula o aumento da exploração em direção ao suposto máximo global.

Os parâmetros  $r_1$  e  $r_2$  são números aleatórios distintos no intervalo  $[0, 1]$ . A maioria das implementações usam dois números aleatórios estocasticamente independentes para variar a força relativa tanto do  $p_{best}$  quanto do  $g_{best}$ . Esta introdução de um elemento aleatório na otimização destina-se a simular o leve componente imprevisível de comportamento de um enxame natural. O parâmetro  $w$  é conhecido como o peso inercial e este número determina em que medida a partícula permanece ao longo de seu curso original afetado pela força da  $p_{best}$  e  $g_{best}$ . O movimento da partícula pode ser traçado com base em (4.1). As partículas mais distantes da  $g_{best}$  ou  $p_{best}$  sentem a maior “atração” por parte dos respectivos locais, e,

portanto, avançam em direção a eles mais rapidamente do que uma partícula mais próxima. A partícula continua a ganhar velocidade na direção dos locais de maior aptidão até que passe por cima deles. Nesse ponto, elas começam a ser puxadas para trás na direção oposta. São estes sobrevoos dos valores máximos globais e locais que muitos acreditam ser o segredo para o sucesso do PSO [97].

Uma vez que a velocidade tenha sido determinada, é simples mover cada partícula ao seu próximo local. A velocidade é aplicada a um passo  $\Delta t$  determinado, geralmente escolhido como 1 e novas coordenadas  $x_n$  são calculadas para cada uma das  $N$  dimensões de acordo com a seguinte equação:

$$x_{(n+1)} = x_n + v_{(n+1)}\Delta t \quad (3-17)$$

A partícula é então movida para o local calculado por (3-18), onde  $\Delta t$  é geralmente definido como 1, e por esta razão muitos autores omitem  $\Delta t$  na equação (3-18). A natureza da composição do algoritmo composto por vários agentes independentes torna especialmente propícia a implementação em processadores paralelos [99].

Assim, o algoritmo de otimização por Enxame de Partículas pode ser resumido da forma que segue:

1. Defina a função objetivo.
2. Defina os valores  $X_{minn}$  e  $X_{maxn}$  do vetor N-dimensional.
3. Inicialize aleatoriamente o enxame de partículas (vetores N-dimensionais), calculando os respectivos  $p_{best}$  e o  $g_{best}$ .
4. Calcule a velocidade de cada partícula através da equação (3-17).
5. Calcule a nova posição de cada partícula, atualizando  $p_{best}$  e  $g_{best}$ .
6. Verifique se os critérios de parada foram satisfeitos, do contrário retorne ao passo 4.

### 3.3.1. Critérios de Parada

A otimização por enxame de partículas continua buscando a melhor solução até que sejam satisfeitos seus critérios de parada. Normalmente, são implementados os seguintes critérios de parada:

- Número Máximo de Iterações: Através deste critério o processo se repete um determinado número de vezes definido pelo usuário, independentemente do resultado obtido
- Condição Término de Aptidão: O PSO repete o processo iterativo e a cada repetição verifica se foi encontrada uma solução que é maior ou igual a um valor de aptidão meta definido pelo usuário. Isso é útil quando se tem um objetivo muito específico para o valor da função de aptidão, e não há necessariamente a preocupação em encontrar a melhor solução. Em alguns casos, se for encontrada uma solução para ser melhor do que a aptidão de destino, então a solução é boa o suficiente e não há nenhuma razão para continuar.
- Desvio Padrão Mínimo: Esta condição, que pode ser utilizada em qualquer combinação com os demais critérios, compara o desvio padrão médio de todas as partículas com o Desvio Padrão Mínimo. Se o desvio padrão atual é menor do que o mínimo determinado pelo usuário, então é dito que todas as partículas convergiram em torno de uma solução de forma satisfatória, e o PSO é finalizado com a suposição de que estagnação.

## **4. MATERIAIS E MÉTODOS**

Neste capítulo será apresentado como foi desenvolvido o sistema para auxílio no planejamento do despacho diário de Pequenas Centrais Hidrelétricas. Inicialmente será abordado como foi construído o sistema de previsão de comportamento limnimétrico de reservatórios a partir da metodologia de Redes Neurais Artificiais. Em seguida, será demonstrado como foi realizada a união da metodologia de RNA com a de Otimização por Enxame de Partículas para construção do cenário otimizado de despacho de PCHs.

### ***4.1. SISTEMA DE PREVISÃO***

O sistema de previsão foi elaborado com o propósito de verificar se é possível realizar a previsão do comportamento do nível de reservatório de Pequenas Centrais Hidrelétricas utilizando Redes Neurais Artificiais. O modelo escolhido seguiu as orientações de [41] onde, para bacias de médio porte, a previsão deve ser feita com os dados de precipitação observados.

Foi desenvolvido um modelo utilizando o tripé de informações: nível, chuva à montante e vazão. A função que se deseja aproximar pela Rede Neural segue a hipótese que o comportamento do nível do reservatório pode ser previsto através da informação de chuva à montante – água que irá chegar ao reservatório – e da vazão consumida – água que está sendo retirada do reservatório, como pode ser observado na figura 4.1.

#### **4.1.1. Base de informações**

Para desenvolvimento do sistema de previsão de nível limnimétrico em reservatórios é necessária a disponibilização de uma base de dados com registros pluviométricos, conjugada com as informações correlatas de nível registrado e vazão utilizada para que o sistema possa extrair conhecimento a partir dos exemplos disponíveis.

No estudo proposto foram escolhidas três variáveis para elaboração da Rede Neural:

- Nível do reservatório: variável a ser prevista, é necessário que o sistema conheça seu histórico para que possa aprender como as demais variáveis impactam em seu comportamento;

- Chuva à montante: índices pluviométricos percebidos em estações de monitoramento a montante do reservatório, que percebam algum valor de chuva que atinge a área drenada e termina no reservatório;
- Vazão consumida: neste modelo foi modelada pela geração da usina, visto a relação linear existente entre ambas para a PCH em estudo.

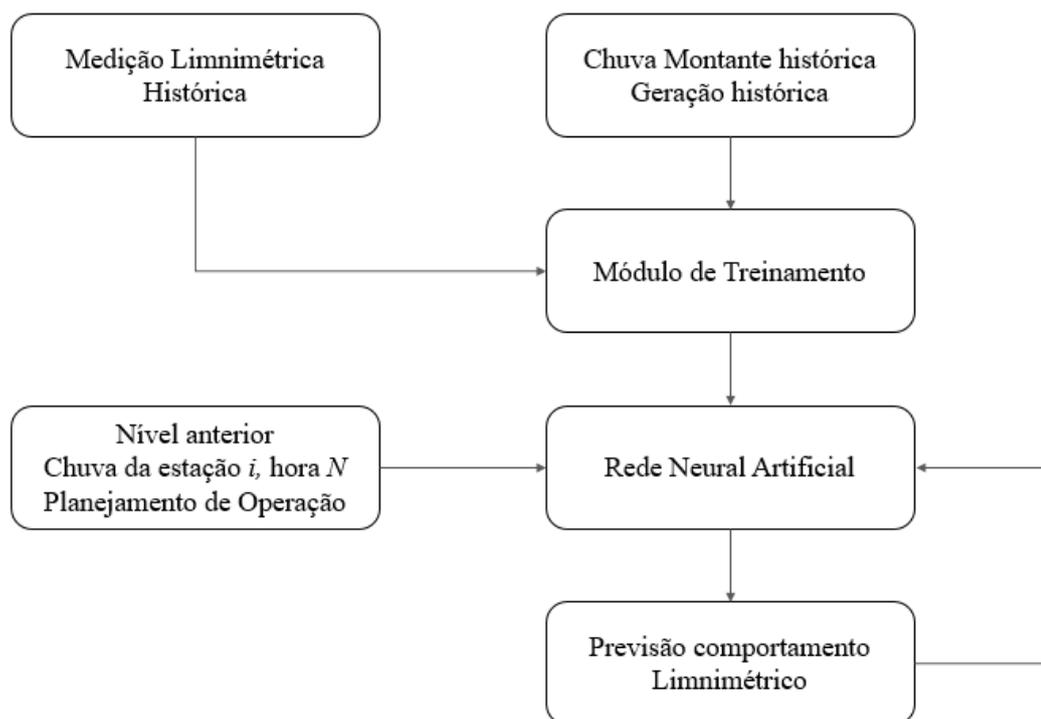


Figura 4.1 – Fluxo de funcionamento do sistema desenvolvido.

A base de dados foi construída conjugando a informação de diferentes fontes.

As informações históricas de geração e nível do reservatório foram obtidas através de base de dados fornecida pela detentora da concessão pública de uso da central hidrelétrica, responsável pela operação e manutenção do ativo. A base de dados disponibilizada contém os registros de geração para ambas as unidades e o valor de nível em metros acima do nível do mar – MANM – do reservatório, em base horária, desde o ano de 2011.

Para os dados pluviométricos, foram utilizadas as informações disponíveis da rede de estações meteorológicas coordenada pelo Centro Estadual de Monitoramento e Alerta de Desastres Naturais do Rio de Janeiro – CEMADEN-RJ, que é uma entidade ligada a Secretaria

de Estado de Defesa Civil, possuindo o objetivo de fornecer e embasar informações relativas aos fenômenos naturais que possam causar dano ao estado.

A base consiste em registros em base horária do volume de chuva registrado nos pluviômetros das estações fluviométricas, além das informações de localização geográfica das estações, e o município de localização, possuindo registros a partir do ano de 2013, de acordo com a estação buscada

Para escolha das estações, foram utilizadas as coordenadas geográficas das estações pertencentes ao município de Três Rios e vizinhos, sendo as estações geograficamente localizadas em imagem de satélite através do software *Google Earth*®. Em seguida, foram delineadas as calhas hídricas da bacia em análise e suas respectivas áreas de drenagens através das informações disponibilizadas pela Agência Nacional de Águas – ANA. Os arquivos são disponibilizados pela ANA em formato *shape* e foram editados com auxílio do *software* livre *QGis*®. As informações das calhas hidrográficas também foram exportadas para o software *Google Earth*®, referenciadas pela localização geográfica média da bacia, sendo em seguida reforçada manualmente a calha dos rios para melhor análise.

Desta forma, foi estabelecido um primeiro filtro onde foi visualmente observado quais estações meteorológicas monitoram informações pluviométricas com aparente relevância para a sub-bacia analisada, através das condições de relevo e área drenada. O resultado da construção pode ser visualizado na figura 4.2, onde o relevo foi retirado da imagem para melhor visualização da calha fluviométrica.



Figura 4.2 – Geolocalização das estações meteorológicas a montante do reservatório.

Através da análise geográfica foi possível verificar que as estações Águas Claras, Centro, Rio Bahia, Estrada Teresópolis / Nova Friburgo, Bonsucesso, Vargem Grande, Morro dos Pinheiros e Jardim Meudom indicavam possuir relevância para drenagem da sub-bacia analisada.

O passo seguinte foi confirmar a relevância de cada estação, e também o tempo de percepção da chuva medida até o reservatório da central hidrelétrica, dado o tempo de viagem da água através do rio. Isto foi realizado através da verificação da correlação entre as variáveis.

Em probabilidade e estatística, correlação é qualquer relação dentro de uma ampla classe de relações estatísticas que envolva dependência entre duas variáveis. Embora seja comumente denotada como a medida de relação entre duas variáveis aleatórias, correlação não implica causalidade. Isto é, a correlação busca avaliar se existe relação linear entre duas variáveis. A correlação é a medida padronizada da relação entre duas variáveis e indica a força e a direção do relacionamento linear entre duas variáveis aleatórias. Assim,

- A correlação nunca pode ser maior do que 1 ou menor do que -1.
- Uma correlação próxima a zero indica que as duas variáveis não estão linearmente relacionadas.
- Uma correlação positiva indica que as duas variáveis se movem juntas; a relação é forte quanto mais a correlação se aproxima 1.
- Uma correlação negativa indica que as duas variáveis se movem em direções opostas; a relação fica mais forte quanto mais próxima a correlação de -1.
- Duas variáveis que estão perfeitamente correlacionadas positivamente ( $r=1$ ) movem-se essencialmente em perfeita proporção na mesma direção.
- Dois conjuntos que estão perfeitamente correlacionados negativamente ( $r=-1$ ) movem-se em perfeita proporção em direções opostas.

Para analisar a relevância da contribuição da chuva percebida pelas estações para a sub-bacia de análise foi traçada a correlação entre o índice pluviométrico e o comportamento limnimétrico da central hidrelétrica. A percepção de vazão utilizada foi monitorada através da variável de geração, uma vez que estas são linearmente dependentes.

Para cálculo da correlação foi utilizado o software *Matlab*® através da função *crosscor*. Esta função calcula e apresenta o correlograma entre duas séries temporais univariadas. O

correlograma entre as estações pluviométricas e a série de nível do reservatório pode ser observado na Figura 2.

Pela análise da correlação entre as variáveis foi possível verificar que todas as estações selecionadas no filtro anterior possuem relevância para o estudo, dado os índices de correlação na ordem de 0,3, com atrasos na ordem de 26 unidades de tempo, o que, para a base de dados analisada, pode ser interpretado como uma relevância no comportamento limnimétrico, em média, 26 horas após a percepção de chuva pelas estações. Este resultado influenciará na definição das variáveis de entrada, conforme será apresentado nas próximas seções.

Confirmada as estações cujo índice possui relevância para o estudo da sub-bacia, a base de informações foi construída tendo como índice chave o selo de tempo data/hora para concatenar as bases em uma só.

#### 4.1.1. Treinamento da RNA

De posse da base de informações o passo seguinte foi o desenvolvimento de um programa para treinamento de Rede Neural Artificial e simulação de resultados.

Para treinamento de uma Rede Neural MLP é necessária a disponibilização de três bases de informação distintas: Base de Treinamento, Base de Validação e Base de Teste.

Nos primeiros modelos que foram desenvolvidos, foi observado que a Rede Neural era treinada com sucesso, obtendo resultados precisos e satisfatórios para a primeira simulação, porém, esta mesma rede treinada, quando utilizada para previsão em períodos climáticos diferentes, apresentava previsões com resultados de qualidade inferior. Após estudo do modelo, foi compreendido que a característica sazonal do regime climático Brasileiro estava interferindo com o treinamento da rede. Para contornar esta situação foi alterada a forma de divisão das bases. No modelo final desenvolvido é inicialmente separada a Base de Previsão do tamanho do horizonte de previsão desejado, 24 (vinte e quatro) horas neste estudo, em seguida, a base completa é integralmente dividida, mês a mês, na proporção 2/3 (dois terços) de cada mês para base de treinamento e o 1/3 (um terço) restante de cada mês para construção da base de validação. Isto assegurou que a rede neural possuísse o conhecimento da característica de cada mês, e conseqüentemente do comportamento sazonal do clima Brasileiro, propagando os resultados satisfatórios para todas as simulações nos diferentes períodos climáticos. A figura 4.4 representa graficamente a separação das bases.

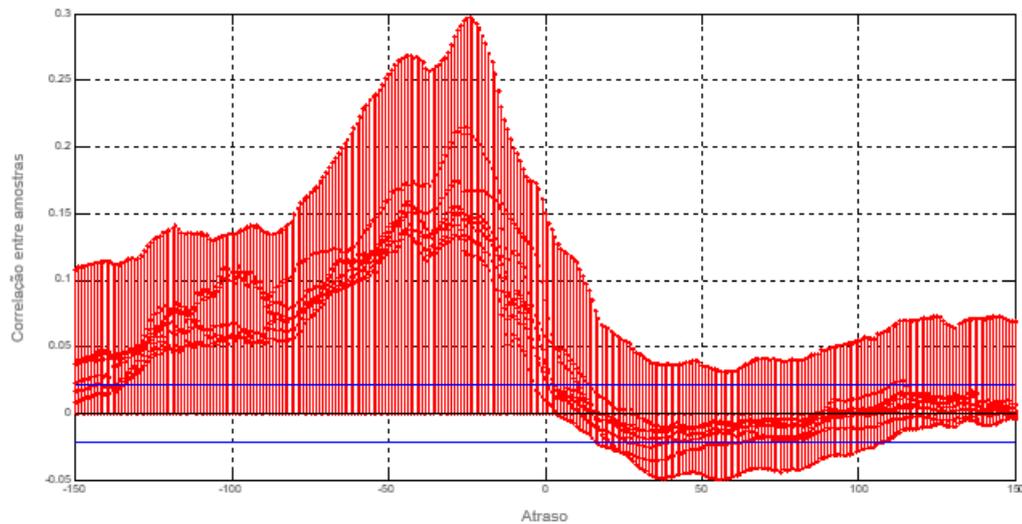


Figura 4.3 – Análise da correlação existe entre a chuva observada a montante e o comportamento limnimétrico do reservatório

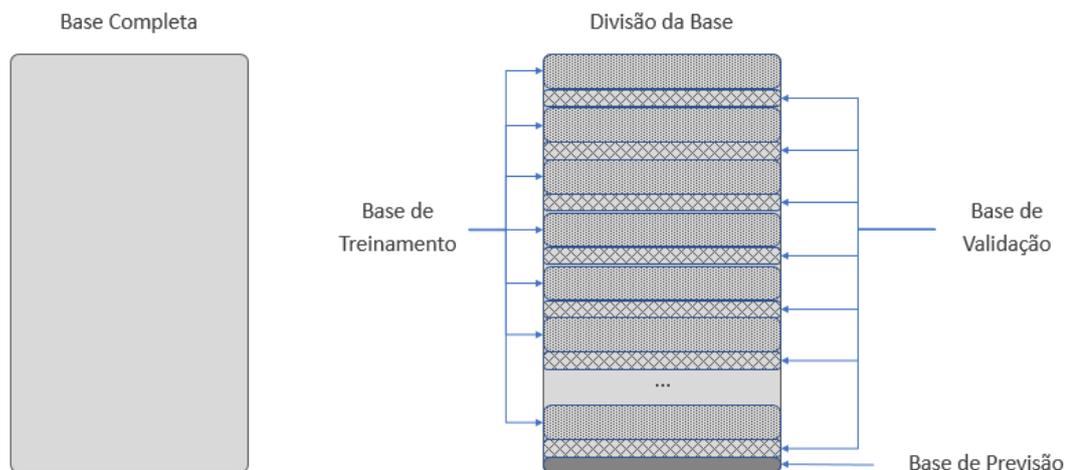


Figura 4.4 – Representação gráfica da separação das bases para treinamento da RNA

A normalização das informações é uma etapa fundamental para o treinamento de RNAs como explicado por [49]. Para desenvolver a Rede Neural Artificial para previsão do comportamento limnimétrico de reservatórios foi optado por normalizar as informações fornecidas ao programa com Valor Máximo = 1 e Valor Mínimo = -1. Os demais valores são linearmente correlacionados dentro deste limite através da equação (4-1).

$$y_{norm} = \frac{(y_{m\acute{a}x} - y_{min}) * (x - x_{min})}{(x_{max} - x_{min})} (y_{min}) \quad (4-1)$$

Onde  $y_{m\acute{a}x}$  e  $y_{min}$  representam, respectivamente, os valores maximos e mınimos na escala normalizada,  $x_{max}$  e  $x_{min}$  os valores maximos da variavel a ser normalizada,  $x$  o valor a ser normalizado e  $y_{norm}$  o seu valor correspondente normalizado.

A Rede Neural utilizada neste trabalho tomou por base um modelo *feedforward* com metodo de automatizacao do processo de especificacao e treinamento baseada em Inferncia Bayesiana aplicada ao MLP.

A arquitetura da rede foi definida atravs do nmero mınimo de neurnios na camada escondida variando entre  $n_{min} = 1$  e  $n_{m\acute{a}x} = 30$ . Apesar de escolhido de forma heurstica, este nmero maximo foi definido tendo em mente o nmero de padres disponveis para treinamento e a quantidade de parmetros a serem estimados. Aps as primeiras simulaces, foi observado que o nmero de neurnios da camada escondida convergia para intervalo entre 8 e 13. Os parmetros da RNA foram ento ajustados para  $n_{min} = 5$  e  $n_{m\acute{a}x} = 20$  para otimizacao do tempo de processamento.

A funcao de transferncia define a sada do neurnio em funcao do nvel de atividade na entrada. Segundo [88] a funcao logstica ou sigmide  a funcao de ativacao ou transferncia mais utilizada em RNAs. Foi adotada a funcao tangente hiperblica na camada oculta e para a camada de sada neurnios do tipo linear.

A RNA foi treinada atravs do algoritmo Bayesiano (3.11) com as condices de parada definidas: nmero maximo de pocas igual a 500, erro medio quadrtico durante o treinamento menor que  $1e-10$  e parmetro de regularizacao do algoritmo de Levenberg-Marquardt superior a  $1e+10$ .

Os valores iniciais dos pesos sinpticos e dos bias foram definidos segundo o modelo do algoritmo de Nguyen-Widrow [100]. Este algoritmo inicializa os pesos da rede de tal forma a garantir que no incio do treinamento os neurnios da camada oculta estejam trabalhando em sua faixa de operacao linear.

Para treinamento da Rede Neural foi desenvolvido um programa no software Matlab® na versão R2015a, utilizando a Toolbox de Redes Neurais. Foi escolhida uma RNA do tipo *perceptrons* de múltiplas camadas (*multilayered perceptron* - MLP).

Os parâmetros adotados foram configurados no programa através das funções específicas assim como o ajuste inicial dos pesos.

O programa recebe as informações da Base de Informações carregando os dados em vetores adequados, separando as diferentes bases. Em seguida é realizada a normalização das informações para correta operação do algoritmo de treinamento.

É então realizado o treinamento das Redes Neurais Artificiais de acordo com a quantidade de neurônios na camada oculta estipulado e validação através do método de validação cruzada [92].

Para cada Rede é calculado o Erro Absoluto Percentual Médio – EAPM – da previsão através da equação (4-2).

$$EAPM = \frac{\sum_{t=1}^n \left( \left| \frac{V_{prevista} - V_{real}}{V_{real}} \right| \right)}{n} \quad (4-2)$$

onde  $V_{prevista}$  é a previsão realizada pela RNA,  $V_{real}$  o valor real da informação e  $n$  o índice do padrão em análise.

A RNA com menor EAPM é escolhida, sendo definido o número de neurônios na camada oculta. A Rede é então treinada com o histórico completo de informações.

#### 4.1.2. Simulações realizadas

Neste estudo foram executados dois experimentos distintos para avaliar o desempenho das RNAs para previsão de comportamento limnimétrico de reservatórios de pequena acumulação.

##### 4.1.2.1. Experimento 1

A ideia principal do experimento 1 foi de verificar os resultados da Rede utilizando somente dados de nível como entrada da rede, e avaliando como seria possível prever o comportamento futuro do nível a partir desse conjunto de dados. Para isso, foram utilizados

cinco horas de elevação de reservatório passado para prever 24 (vinte e quatro) de nível futuro. O período de cinco horas de nível passado foi escolhido de forma arbitrária.

Foram realizadas previsões para o intervalo de 2014 a 2016, para os quatro períodos climáticos (úmido, transição úmido x seco, seco e transição seco x úmido) objetivando verificar a validade da Rede para diferentes condições de precipitação.

A figura 4.5 ilustra a resposta das Redes Neurais treinadas para o experimento 1. Exemplo de previsão para o período chuvoso (figura 4.5a), período de transição entre o período chuvoso e o período seco (figura 4.5b), previsão para o período seco (figura 4.5c) e transição seco para período de chuvas (figura 4.5d). A linha azul se refere as informações de nível histórico reais, a linha vermelha representa o aprendizado da Rede Neural em relação ao comportamento do nível. Em seguida, o horizonte real é traçado pela linha verde. A Rede Neural não recebe estas informações; baseada nos seus parâmetros internos, a RNA prevê um comportamento baseado em suas entradas, representada pela linha preta.

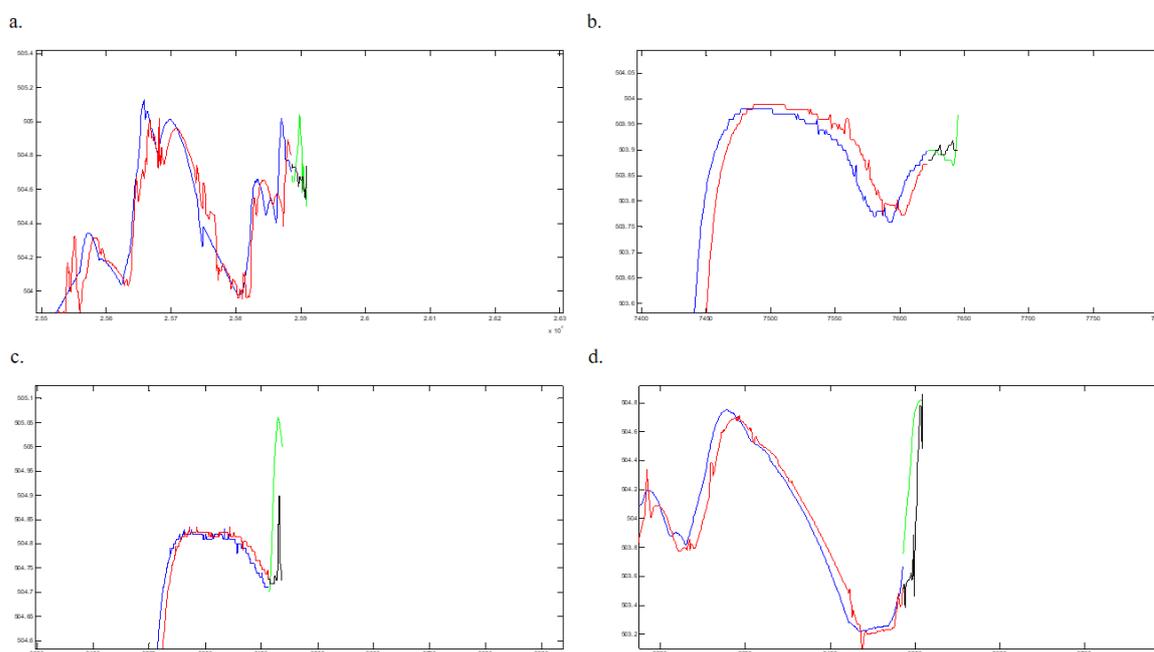


Figura 4.5 – Representação gráfica das previsões obtidas no experimento 1

#### 4.1.2.2. Experimento 2

O experimento 2 teve por objetivo verificar os resultados da Rede com a adição da precipitação observada, de forma que a RNA treinada realize a previsão do comportamento do nível do reservatório utilizando também a informação de chuva observada a montante.

Como foi explicado na seção 4.2, a chuva de montante demora, em média, 26 horas para atingir a bacia estudada, desta forma, não é necessário utilizar a previsão do tempo para previsão do comportamento do nível das próximas 24 horas, pois existe “sobra” de informação de 2 horas.

Novamente foram realizadas previsões para o intervalo de 2014 a 2016, para os quatro períodos climáticos (úmido, transição úmido x seco, seco e transição seco x úmido) objetivando verificar a validade da Rede para diferentes condições de precipitação. As respostas obtidas para o experimento 2 podem ser vistas na figura 4.6.

Novamente, exemplo de previsão para o período chuvoso (figura 4.6a), período de transição entre o período chuvoso e o período seco (figura 4.6b), previsão para o período seco (figura 4.6c) e transição seco para período de chuvas (figura 4.6d).

Assim como no experimento 1, a linha azul se refere as informações de nível histórico reais, a linha vermelha representa o aprendizado da Rede Neural em relação ao comportamento do nível. Em seguida, o horizonte real é traçado pela linha verde, a Rede Neural não recebe estas informações, baseada nos seus parâmetros internos, a RNA prevê um comportamento baseado em suas entradas, representada pela linha preta.

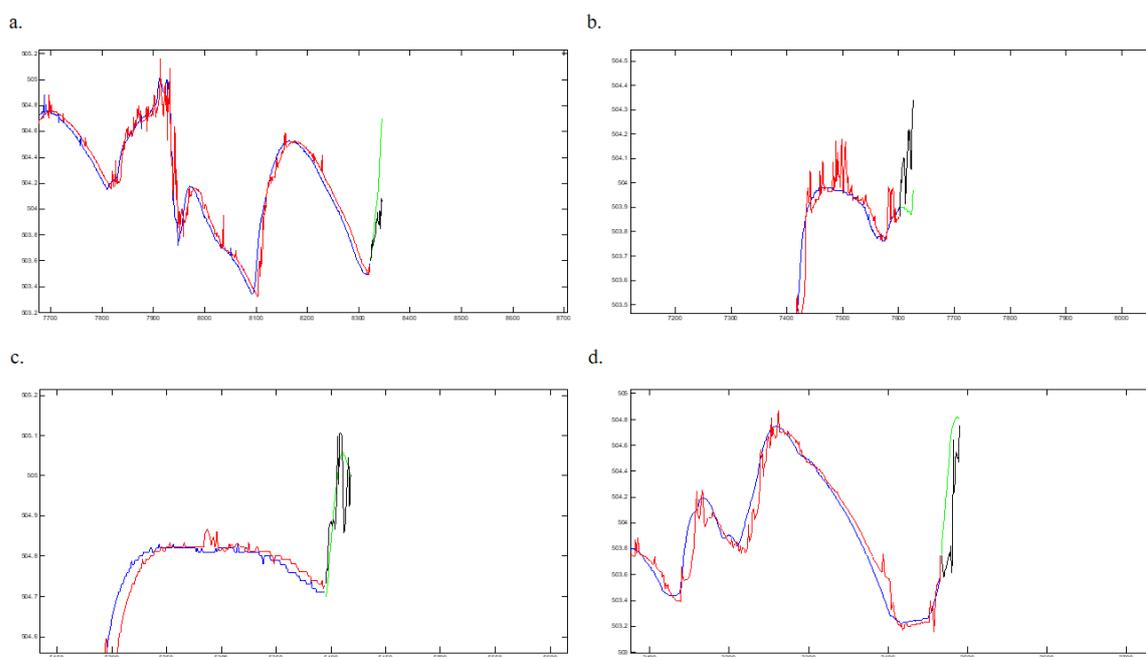


Figura 4.6 – Representação gráfica das previsões obtidas no experimento 2

#### 4.1.3. Resultados do Sistema de Previsão

Esta seção consistiu em modelar uma Rede Neural Artificial para previsão do comportamento limnimétrico de reservatórios de baixa capacidade de regulação fluviométrica. Foram realizadas duas experimentações com dados de entrada diferentes para avaliação do melhor resultado de previsão. Foram utilizadas redes multicamadas do tipo *perceptron*, ou MLP (*multi-layer perceptron*).

Em razão da sazonalidade climática, cada um dos dois experimentos foi submetido a diferentes períodos de previsão, para verificar a adequação da previsão para os diferentes períodos de pluviometria (úmido, transição úmido x seco, seco e transição seco x úmido).

Os parâmetros de configuração da Rede Neural Artificial, bem como a separação de bases, definição de pesos iniciais e método de normalização das informações foram detalhados na seção 4.1.2.

Foram simuladas as previsões para os anos de 2014 a 2016, para cada um dos 4 períodos climáticos, totalizando 12 simulações para cada experimento.

O resultado de cada previsão foi avaliado em termos do Erro Absoluto Percentual Médio, do inglês, *Mean Absolut Percentage Error*. O resultado dos experimentos pode ser verificado nas tabelas 4.1 a 4.4.

Tabela 4-1 – Previsões obtidas utilizando RNAs para o período chuvoso

Ano	EAPM simulação com precipitação	EAPM simulação sem precipitação
<b>2014</b>	0,0449	0,1153
<b>2015</b>	0,0383	0,0172
<b>2016</b>	0,0289	0,0246

Na tabela 4-5 é possível verificar que a utilização da informação da chuva de montante trouxe ganho na previsão para todos os períodos climáticos. A tabela 4-6 permite mensurar o ganho obtido com o acréscimo da informação da chuva de montante, nela pode ser observado

que a média de erros absolutos percentuais é 31% inferior para previsões utilizando a chuva de montante como dado de entrada quando comparada com as previsões realizadas com base no registro histórico.

Tabela 4-2 – Previsões obtidas utilizando RNAs para o período de transição chuvoso x seco

Ano	EAPM simulação com precipitação	EAPM simulação sem precipitação
<b>2014</b>	0,0110	0,0038
<b>2015</b>	0,0100	0,0209
<b>2016</b>	0,0115	0,0103

Tabela 4-3 – Previsões obtidas utilizando RNAs para o período seco

Ano	EAPM simulação com precipitação	EAPM simulação sem precipitação
<b>2014</b>	0,0112	0,0122
<b>2015</b>	0,0020	0,0059
<b>2016</b>	0,0061	0,0057

Tabela 4-4 – Previsões obtidas utilizando RNAs para o período de transição seco x chuvoso

Ano	EAPM simulação com precipitação	EAPM simulação sem precipitação
<b>2014</b>	0,0122	0,0990
<b>2015</b>	0,0285	0,0282
<b>2016</b>	0,0371	0,0103

Tabela 4-5 – Média dos EAPM's obtidos nas previsões

Período	EAPM simulação com precipitação	EAPM simulação sem precipitação
<b>Chuvoso</b>	0,0373	0,0523
<b>Chuvoso x Seco</b>	0,0108	0,0116
<b>Seco</b>	0,0064	0,0079
<b>Seco x Chuvoso</b>	0,0259	0,0458

Tabela 4-6 – Resumo dos EAPM's obtidos nas previsões

Resumo	EAPM simulação com precipitação	EAPM simulação sem precipitação
<b>Média</b>	0,0201	0,0294

#### **4.2. METODOLOGIA PARA APOIO AO PLANEJAMENTO DO DESPACHO DIÁRIO DE PEQUENAS CENTRAIS HIDRELÉTRICAS**

O objetivo deste método é apresentar cenários de geração para auxiliar na decisão da programação diária de geração de centrais hidrelétricas. A questão do despacho diário é mais relevante em usinas de pequena ou nenhuma acumulação de água, uma vez que o despacho incorreto nestes casos pode acarretar em erros no equacionamento do volume de espera, levando a vertimentos indevidos, operação fora das faixas de rendimento ideais ou até mesmo a necessidade de parada da central por falta de recurso hídrico.

O sistema cria cenários de geração considerando as informações reais nas últimas 24 horas de precipitação à montante do reservatório, observadas nas estações da rede de monitoramento pluviométrico, uma vez que segundo a correlação de variáveis, a chuva de montante começa a exercer influência no comportamento do reservatório 26 horas após sua observação. O sistema apresenta diferentes valores de geração e os valores reais de precipitação à RNA treinada, verificando a previsão de comportamento do reservatório para cada condição, buscando os melhores valores de produção para o despacho diário.

Dentre as diferentes possibilidades para controle do sistema, foi optado neste estudo pela parametrização a partir das políticas de descarga do reservatório, denominadas curvas-guias, que consiste na divisão do volume útil do reservatório em diferentes zonas que possuem políticas de descargas específicas [67]. No caso de reservatórios de pequena ou nenhuma acumulação é comum operar com apenas uma zona de descarga, segundo *expertise* da equipe de operação da usina estudada. Desta forma, o sistema foi implementado para atender a informação de limite inferior de cota, relacionado aos melhores rendimentos do conjunto turbina x gerador, e limite superior de cota, relacionado ao volume de espera ideal do reservatório. Apesar de ser comum a variação de tais limites de acordo com a época do ano, o sistema não foi previamente desenvolvido levando em consideração esta característica, à saber, valores inferiores e superior diferentes para cada época do ano, uma vez que o sistema objetiva o planejamento de curto prazo de PCHs, ou seja, o despacho diário, e não o planejamento de médio e longo prazo, isto é, trimestral ou anual, por exemplo. A decisão da utilização das curvas-guia foi motivada pelo bons resultados obtidos em estudos com a utilização desta metodologia [68]–[74].

As curvas-guia da central que foi utilizada como referência neste estudo podem ser observadas na Figura 4.7.

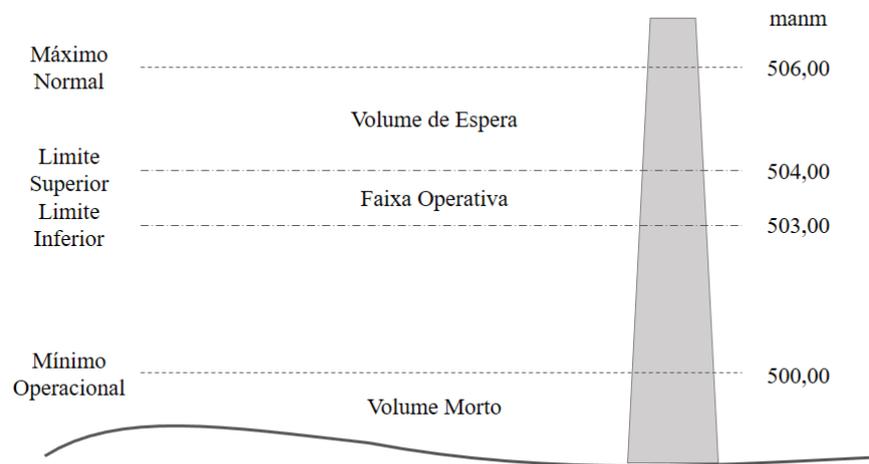


Figura 4.7 – Curvas-guias da central estudada

São apresentados dois cenários diferentes para o sistema de auxílio à tomada de decisão de despacho. O primeiro cenário apresenta valores de geração iguais para as próximas 24 horas, denominado despacho *flat*, uma vez que esta é a modalidade de programação atual da usina.

Assim, o sistema indica a melhor condição de despacho desta forma, isto é, a maior geração possível nas próximas 24 horas, com o mesmo valor de produção a cada hora, atendendo os limites operacionais.

O segundo cenário busca apresentar a condição otimizada de geração. Baseado na informação de chuva a montante, nos limites operacionais, na previsão de comportamento do reservatório, informa a programação ideal de geração para cada hora que retorna o melhor valor total de despacho no período alvo, respeitando as regras de descarga definidas. Esta condição não é a regra utilizada atualmente na central estudada mas espera-se que faça melhor uso do recurso hídrico, e conseqüente retorno financeiro. Além disso uma vez que não são necessários investimentos para implantação, e, a priori, segundo expertise do setor de engenharia da central estudada, não acarreta em perdas técnicas aos equipamentos, não existem impedimentos para mudança no regime de operação da usina.

Além dos limites superiores e inferiores de cota, para elaboração dos cenários de referência, é necessário que o operador informe ao sistema os valores mínimo e máximo possíveis de produção da central em estudo. A central deste estudo pode ser despachada com no mínimo 4 MW até sua potência instalada de 20 MW.

#### 4.2.1. Cenário flat

O objetivo do cenário *flat* é apresentar o melhor valor de produção para o intervalo de 24 horas, utilizando o mesmo valor de produção para cada hora do intervalo, observando as informações de chuva a montante, prevendo qual será o comportamento do reservatório nestas condições e verificando se algum limite de operação é atingido.

Para elaboração deste cenário é solicitado ao usuário que informe o “passo” de crescimento dos testes, isto é, qual o valor que ele deseja que seja acrescido ao valor de teste atual para realização do próximo teste, até atingimento do valor máximo possível de produção.

De forma geral, o algoritmo do cenário *flat* pode ser resumido da forma que segue:

1. Informe os limites inferior e superior da curva-guia do reservatório.
2. Informe os limites de geração  $MW_{min}$  e  $MW_{max}$  da central, e o valor de crescimento a cada iteração  $MW_{passo}$ .
3. Informe a informação de chuva observada nas últimas 24 horas.

4. Inicialize todas as posições do vetor com dimensão igual ao horizonte de análise com o valor mínimo de produção  $MW_{\min}$ .
5. Realize a previsão passo a passo do comportamento do reservatório para o horizonte de análise, verificando extrapolações dos limites.
6. Caso não ocorra ultrapassagem dos limites, atualize a Geração Objetivo,  $MW_{obj}$ , com o valor atual do vetor.
7. Caso o limite inferior tenha sido ultrapassado, defina a Geração Objetivo,  $MW_{obj}$ , com o valor zero.
8. Caso o limite superior tenha sido ultrapassado, defina a Geração Objetivo,  $MW_{obj}$ , com o valor máximo,  $MW_{\max}$ .
9. Incremente todas as posições do vetor com dimensão igual ao horizonte de análise com o valor de crescimento  $MW_{passo}$ .
10. Se o vetor tiver atingido o valor máximo,  $MW_{\max}$ , encerre o sistema, do contrário retorne ao passo 5.

O sistema informa o maior valor de produção possível na modalidade *flat*, armazenado na variável  $MW_{obj}$ , que não extrapola os limites estabelecidos, ou a sugestão de parada de geração caso o limite mínimo seja ultrapassado no horizonte de análise ou geração máxima, caso ocorra a extrapolação do limite máximo.

#### 4.2.2. Cenário otimizado

O cenário otimizado utiliza a metodologia de otimização por Enxame de Partículas, explicada na seção 3.3, para buscar o despacho ótimo do intervalo de 24 horas, não se limitando a considerar o mesmo valor de produção para cada horário, mas seguindo as demais diretrizes do cenário *flat*, à saber, maximizar valor de produção do intervalo, observação das informações de chuva a montante, previsão do comportamento do reservatório para tais condições e verificação de extrapolação dos limites de operação.

Na construção deste cenário são gerados  $N$  vetores aleatórios do tamanho do horizonte de previsão. Para as simulações deste trabalho foram utilizados 30 vetores com 24 posições, e para cada um destes vetores é verificado individualmente, passo a passo do horizonte de previsão, o comportamento do reservatório.

Para que o algoritmo saiba qual vetor apresentou melhor resultado, e qual direção deve ser *seguida* pelos vetores, é necessário pontuar cada vetor. Isto é realizado pela definição de uma função objetivo que fornece um valor único para cada vetor.

A intenção da função objetivo construída para este cenário é a obtenção do cenário ótimo de despacho, sem extrapolação dos limites de operação, assim, a função construída seguiu a fórmula (4-3)

$$P = \sum_{n=1}^h MW_n - Penalidade_n \quad (4-3)$$

Onde o valor da função objetivo  $P$  é igual ao somatório do valor de produção para cada hora  $n$  no horizonte de previsão  $h$  menos um valor de penalidade no caso de violação de alguma das restrições previamente estabelecidas.

Desta forma, para cada um dos 30 vetores aleatórios é definido um único valor de pontuação, que é seu o *pbest* da metodologia PSO, o melhor destes é o *gbest* do sistema para a primeira iteração.

Em seguida, o algoritmo calcula as velocidades de movimento, e atualiza os  $N$  vetores para uma nova posição, calculando os novos *pbest* e *gbest*. Os passos são continuamente repetidos até atingimento de um dos critérios de parada. Neste estudo foram utilizados como critério o número máximo de 3.000 iterações e diferença entre valor global das 3 últimas iterações não superior a 1 kW (0,005% do valor máximo de geração)

A cada iteração o algoritmo obtém um novo vetor cujo cálculo da função objetivo representa o despacho otimizado, isto é, novos valores de despacho em base horária, para as próximas 24 horas, que maximizam a geração da central, respeitando a curvas-guias de geração, e tendo como referência os valores reais observados de chuva a montante.

Desta forma, pode-se resumir o algoritmo de criação do cenário otimizado desta forma:

1. Defina a função objetivo.
2. Informe os limites inferior e superior da curva-guia do reservatório.
3. Informe a informação de chuva observada nas últimas 24 horas.
4. Informe os valores de geração  $MW_{min}$  e  $MW_{max}$  do vetor n-dimensional.

5. Inicialize aleatoriamente o “enxame de partículas” (vetores n-dimensionais).
6. Realize a previsão passo a passo do comportamento do reservatório para o horizonte de análise, para cada um dos  $N$  vetores, verificando extrapolações dos limites, calculando seus  $pbest$  e o  $gbest$ .
7. Calcule a velocidade de cada partícula através da equação (3-17).
8. Calcule a nova posição de cada partícula.
9. Realize a previsão passo a passo do comportamento do reservatório para o horizonte de análise, para cada um dos  $N$  vetores, verificando extrapolações dos limites, atualizando seus Melhores Pessoais e o Melhor Global.
10. Verifique se os critérios de parada foram satisfeitos, do contrário retorne ao passo 7.

A figura 4.8 representa a resposta do método de Otimização por Enxame de Partículas. Pode-se observar a curva de otimização com o crescimento do  $gbest$  que inicia em valores negativos, pois nos primeiros vetores o número de extrapolações, e conseqüentemente de penalidades, é elevado, porém, com o avanço das iterações, o método consegue convergir os vetores para soluções viáveis, maximizando o resultado final e apresentado uma resposta com nenhuma violação.

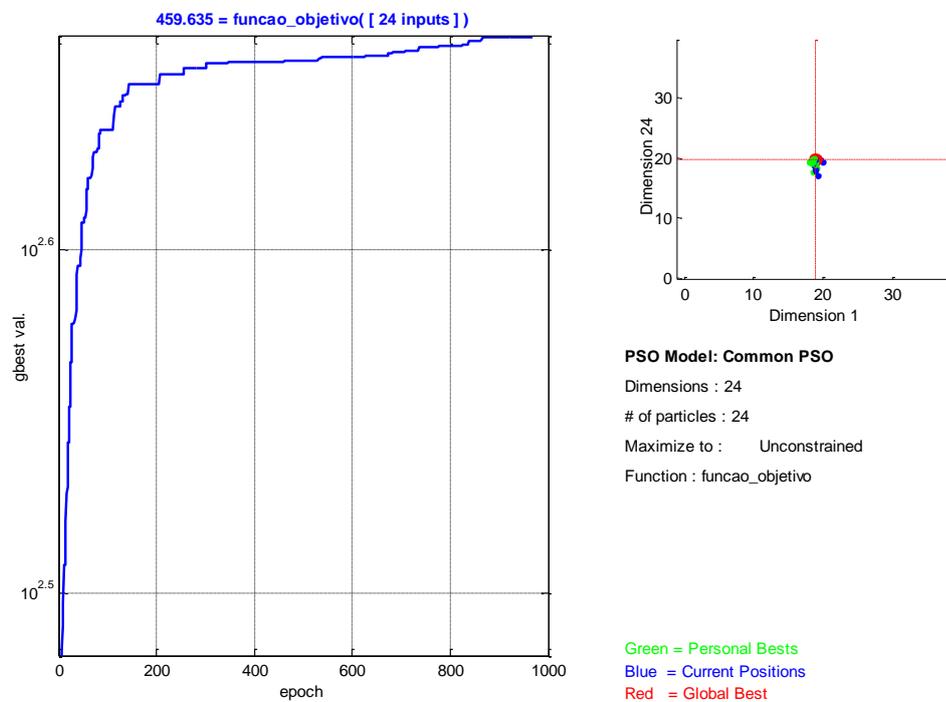


Figura 4.8 – Exemplo do método de otimização por Enxame de Partículas

O método informa o valor otimizado de produção, sendo o vetor que responde pelo *gbest* obtido ao final do processo iterativo. Em alguns casos o melhor vetor obtido pode ter extrapolado os limites estabelecidos em algum intervalo do horizonte de previsão, ainda sim terá sido o vetor que produziu melhor resultado de acordo com a função objetivo desenvolvida, isto é, o vetor final pode informar intervalos de parada de geração (produção igual a zero) ou geração máxima em todo horizonte, e mesmo assim estimar que os limites superior ou inferior do reservatório serão infringidos, baseado em seu conhecimento próprio.

#### 4.2.3. Resultados do sistema para auxílio no planejamento do despacho diário de pequenas centrais hidrelétricas

O objetivo da metodologia desenvolvida consiste em apresentar cenários ideais de geração para auxílio na tomada de decisão do despacho diário de PCHs. O método apresenta dois cenários distintos de geração possível – *flat* e otimizado por Enxame de Partículas.

Após desenvolvimento dos algoritmos de previsão, o método foi testado em diferentes configurações de entrada através de sete diferentes simulações. Buscou-se analisar se os resultados apresentados demonstravam coerência com os índices esperados através da verificação detalhada das respostas apresentadas. Um exemplo desta análise é apresentado através das figuras 4.9 a 4.13.

A primeira indagação que se buscou verificar foi se o método apresentava resultado coerente para as condições reais ocorridas, isto é, se, tendo como entrada os valores reais de chuva, comportamento do reservatório e o despacho que efetivamente ocorreu, o método apresenta uma previsão de comportamento que acompanha a tendência do comportamento real ocorrido. Na figura 4.9 pode ser observado que a previsão realizada, em azul, acompanha a tendência do comportamento real, na cor preta. Desta forma se verifica que a Rede Neural Artificial treinada para o método possui resposta adequada na previsão de comportamento limnimétrico.

Uma vez que se verificou que o método tem a capacidade de acompanhar a tendência real do comportamento limnimétrico do reservatório, a pergunta seguinte que se quis responder foi qual seria a resposta obtida se estipulada geração máxima para todo o horizonte de previsão? Como pode ser observado na figura 4.10, na condição de geração máxima o limite inferior do reservatório é ultrapassado, causando a interrupção do simulador. Os limites superior e inferior

especificados para o método foram 503,00 e 504,00 metros acima do nível do mar, notados em rosa, e a linha azul é a previsão de comportamento limnimétrico no horizonte de 24 horas.

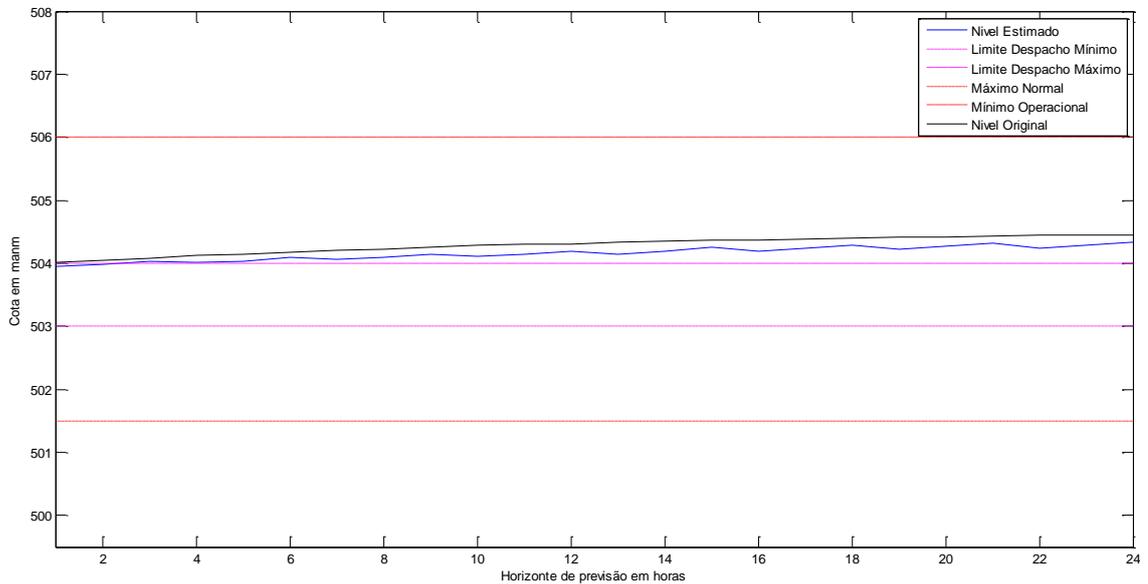


Figura 4.9 – Resposta do método para a entrada real de despacho

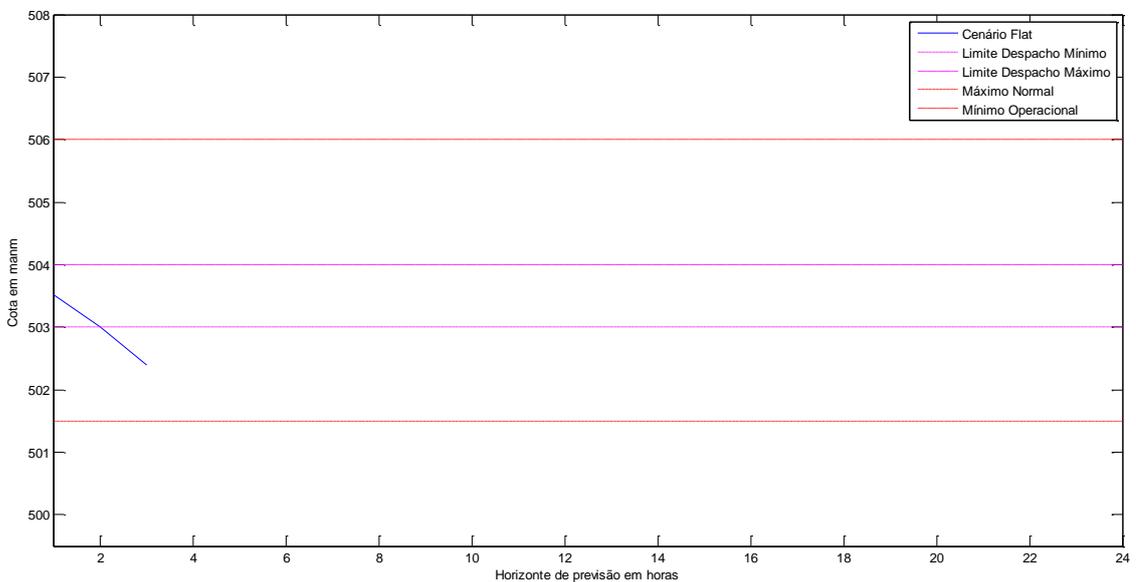


Figura 4.10 – Resposta do método para a entrada máxima de despacho

Realizados os testes iniciais, na sequência foi permitido ao método a apresentação do resultado para a primeira configuração de despacho *flat*. Neste cenário o método recebe as informações de chuva a montante, e de acordo com seu conhecimento adquirido no treinamento,

e da conta anterior de reservatório, verifica o despacho de geração com maior energia total, tendo o mesmo patamar de potência gerada em todos os intervalos do horizonte de previsão, buscando uma produção que não ultrapasse os limites de cota definidos, sendo a potência mínima, máxima e incremento dados de entrada para estimativa.

Neste cenário o método previu que com um despacho *flat* de 17.150 kW é possível regular o nível limnimétrico do reservatório e maximizar a energia gerada, como pode ser observado na figura 4.11, onde novamente os limites superior e inferior estão apontados em rosa e a linha azul representa o comportamento limnimétrico previsto.

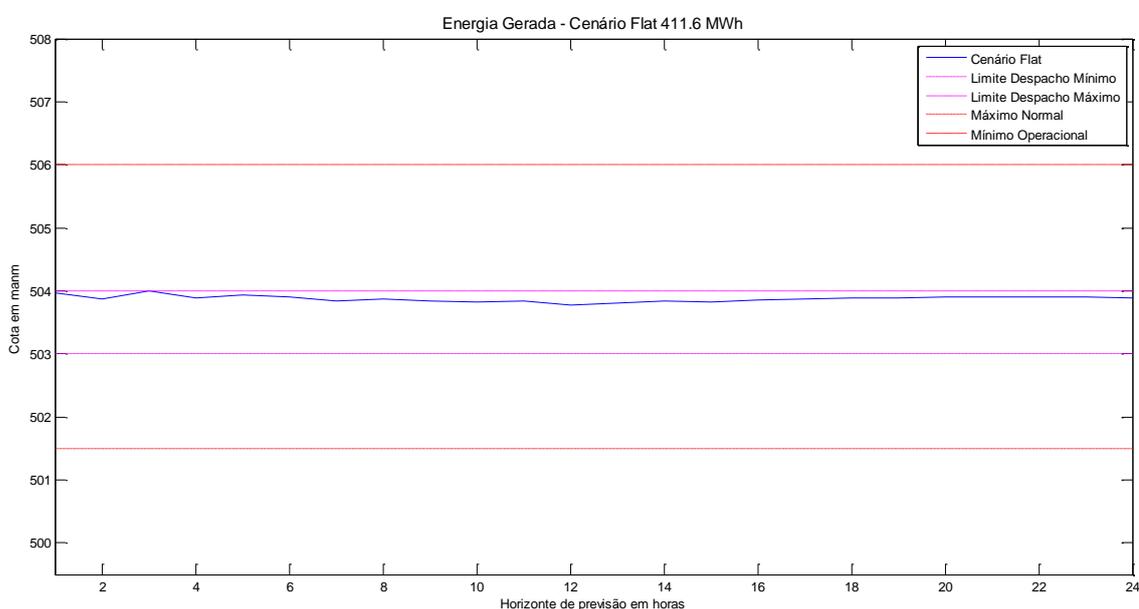


Figura 4.11 – Previsão do método para despacho *flat*

Assim, o método teria auxiliado o despacho da central, ao prever que a programação estipulada para as próximas vinte e quatro horas não seria suficiente para manter o nível do reservatório dentro dos limites desejados. Este nível poderia ter sido controlado caso o despacho fosse programado nos patamares sugeridos pela metodologia.

Entretanto, mesmo com o ganho energético obtido, será que a condição *flat* representa o despacho ótimo da central? O método buscou verificar esta indagação utilizando a metodologia de Otimização por Enxame de Partículas para verificar se despacho *flat* e otimizado eram sinônimos.

A adoção do PSO permite em um tempo computacional dedicado, estimar diversos cenários diferentes de despacho, verificando o melhor destes a cada iteração, e buscando convergir os demais em direção a este. Desta forma, em um número limitado de interações obtém-se a condição otimizada de despacho que busca não ultrapassar os limites estipulados.

O despacho otimizado pelo PSO também conseguiu apresentar um cenário onde os limites de cota não são ultrapassados, assim como o cenário *flat*, entretanto com uma produção energética superior: 461 MWh contra 411 MWh de produção na condição de despacho igual em todo o horizonte de previsão. A figura 4.12 apresenta previsão do comportamento limnimétrico para despacho otimizado.

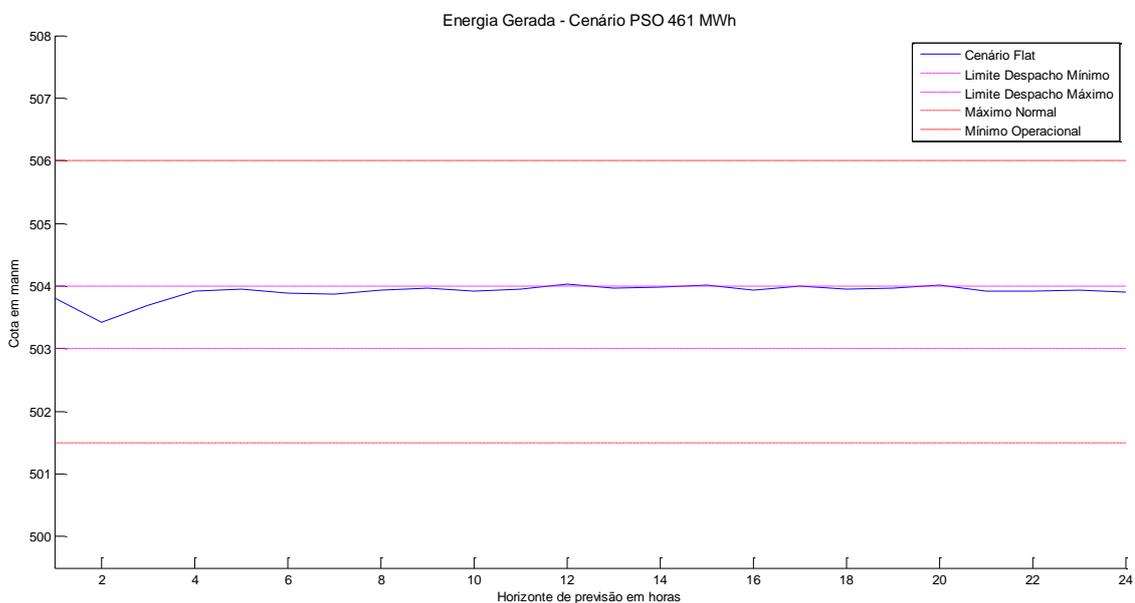


Figura 4.12 – Previsão do método para despacho otimizado por PSO

Assim, segundo a previsão apresentada pelo método, a condição otimizada de despacho para as próximas 24 horas deve ser um despacho com diferentes patamares horários, o que representaria um ganho energético de 12% frente ao despacho *flat*, também realizando o controle e manutenção do nível limnimétrico dentro das condições estipuladas.

A figura 4.13 apresenta os despachos respectivos para cada uma destas condições. O despacho original, que não conseguiu realizar controle do nível dentro das condições estipuladas, é representado pela linha preta. A linha verde é referente ao despacho *flat* com a melhor previsão energética sem extrapolar os limites estipulados e a linha azul demonstra a

condição otimizada de despacho para atender as restrições de despacho e maximizar a produção energética. Os valores referentes a cada série podem ser observados na tabela 4.7.

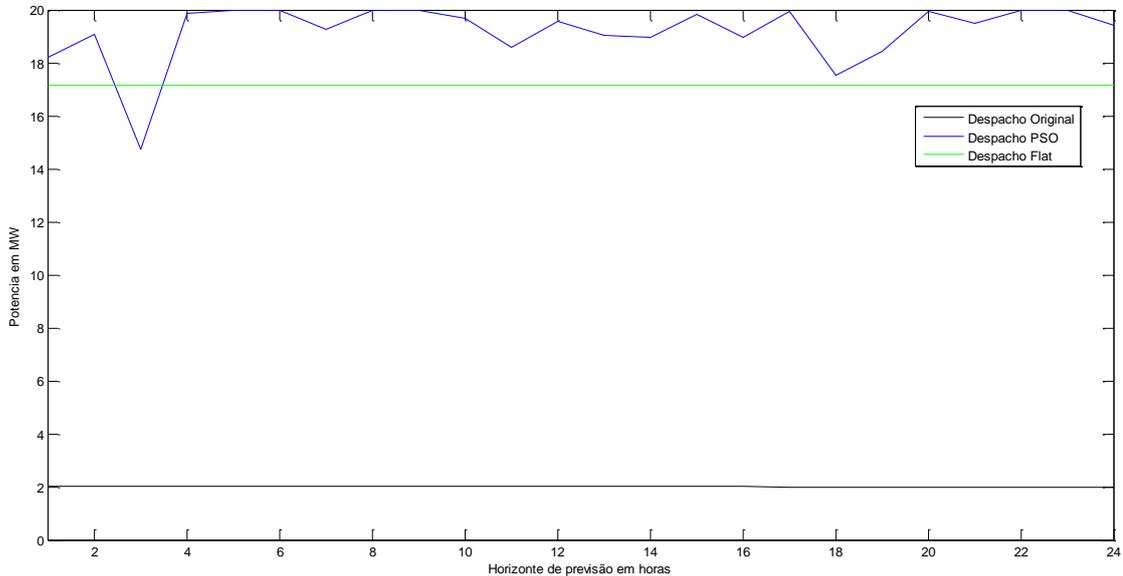


Figura 4.13 – Previsão do método para despacho otimizado por PSO

Uma vez que se verificou a coerência do método desenvolvido, foram simulados diferentes cenários para os anos de 2014 a 2016, em diferentes períodos climáticos. Os resultados dos experimentos podem ser verificados na tabela 4.8. As figuras 4.14 e 4.15 apresentam exemplos do resultado final apresentado pelo método.

Pela análise da tabela 4.8, os cenários gerados com a metodologia de Otimização por Enxame de Partículas apresentaram resultados de programação 20% superiores ao resultado de despacho *flat*, demonstrando os ganhos possíveis com a utilização desta técnica do despacho diário de PCHs.

Conforme foi mencionado anteriormente, a condição de despacho atual da central segue o despacho *flat*. Isso se deve principalmente ao fato da central ser despachada de forma assistida, ou seja, os operadores localizados na própria central realizam a operação, não havendo Centro de Operação remoto, e a estratégia de operação ser definida pela equipe de supervisão da usina, que não fica lotada na mesma e não realiza acompanhamento contínuo das informações de geração, chuva e nível limnimétrico.

Tabela 4-7 – Valores horários de despacho para a simulação analisada

Despacho	Despacho Original MW	Despacho Flat MW	Despacho Otimizado MW
<b>Hora 1</b>	2.001,6	17.150,0	18.198,1
<b>Hora 2</b>	2.001,3	17.150,0	19.076,0
<b>Hora 3</b>	2.000,9	17.150,0	14.717,5
<b>Hora 4</b>	2.001,2	17.150,0	19.885,8
<b>Hora 5</b>	2.000,8	17.150,0	20.000,0
<b>Hora 6</b>	2.000,3	17.150,0	19.994,3
<b>Hora 7</b>	2.004,2	17.150,0	19.277,9
<b>Hora 8</b>	2.005,7	17.150,0	20.000,0
<b>Hora 9</b>	2.005,2	17.150,0	19.974,9
<b>Hora 10</b>	2.005,8	17.150,0	19.679,0
<b>Hora 11</b>	2.005,9	17.150,0	18.571,5
<b>Hora 12</b>	2.002,6	17.150,0	19.555,4
<b>Hora 13</b>	2.002,6	17.150,0	19.041,0
<b>Hora 14</b>	2.002,1	17.150,0	18.943,5
<b>Hora 15</b>	2.001,2	17.150,0	19.817,2
<b>Hora 16</b>	2.001,8	17.150,0	18.975,3
<b>Hora 17</b>	1.996,5	17.150,0	19.947,5
<b>Hora 18</b>	1.994,5	17.150,0	17.526,3
<b>Hora 19</b>	1.995,3	17.150,0	18.443,6
<b>Hora 20</b>	1.997,5	17.150,0	19.954,4
<b>Hora 21</b>	1.996,4	17.150,0	19.488,9
<b>Hora 22</b>	1.996,6	17.150,0	20.000,0
<b>Hora 23</b>	1.996,7	17.150,0	20.000,0
<b>Hora 24</b>	1.996,0	17.150,0	19.433,1

Devido a isso, pode-se dizer que a definição da estratégia de operação é realizada de forma reativa, ou seja, reage ao comportamento limnométrico após as mudanças acontecerem. Desta forma, por diversas vezes na base histórica pode se observar extrapolação dos limites de operação, sem o devido acompanhamento dos valores de despacho, que poderiam evitar e regular o comportamento do reservatório.

Através da adoção do método proposto, o despacho da central teria sua modalidade alterada de *flat* para despacho horário, e passaria a ser um despacho preventivo, com maior capacidade de regulação do comportamento limnométrico, e otimização da produção energética, segundo as previsões apresentadas.

Esta alteração não envolveria alterações físicas na planta, tão pouco necessitaria de novos valores de mão de obra, uma vez que a usina possui despacho local, e também, segundo expertise da equipe técnica responsável pela central, não causaria perdas técnicas ou de vida útil aos equipamentos, uma vez que o despacho em base horária não significa alterações constantes do ponto de operação, sendo uma condição normal de operação dos equipamentos.

Assim, entende-se que o método desenvolvido possui alto potencial de ganho ao alterar a condição de despacho da central e por trabalhar de forma preventiva, otimizando o uso do recurso hídrico, aumentando a eficiência da produção.

Tabela 4-8 – Resultado dos cenários gerador pelo método para Auxílio no Planejamento de despacho de PCH's

<b>Simulação</b>	<b>Previsão de Energia Cenário Flat - GWh</b>	<b>Previsão de Energia Cenário Otimizado GWh</b>
<b>Simulação 1</b>	330	468
<b>Simulação 2</b>	396	442
<b>Simulação 3</b>	411	461
<b>Simulação 4</b>	333	440
<b>Simulação 5</b>	357	446
<b>Simulação 6</b>	422	466
<b>Simulação 7</b>	411	453

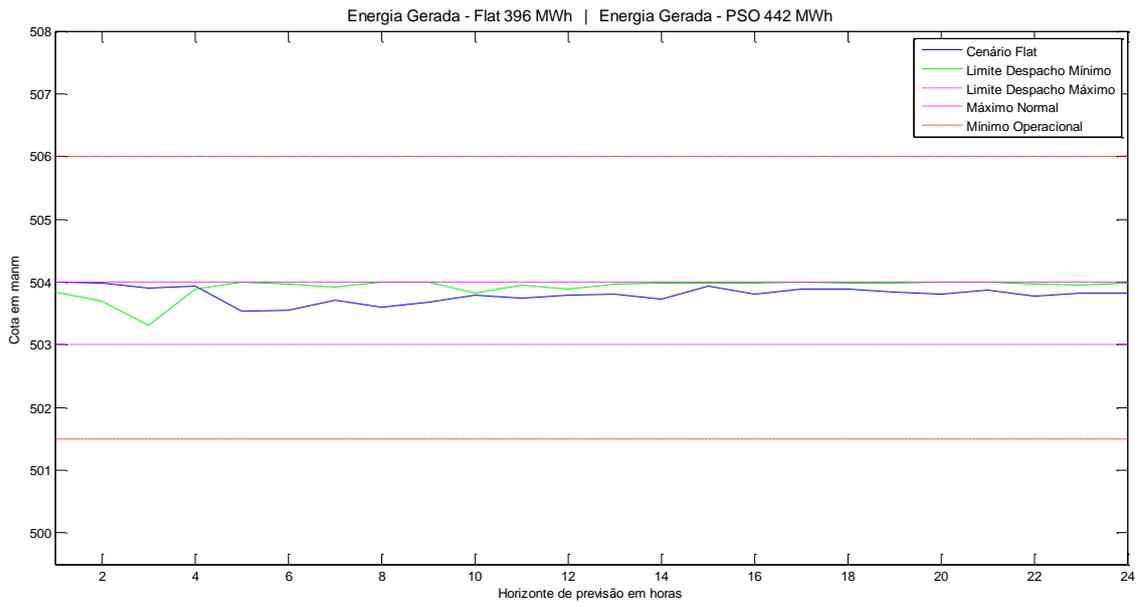


Figura 4.14 – Exemplo de resposta gerada pelo método, simulação 2

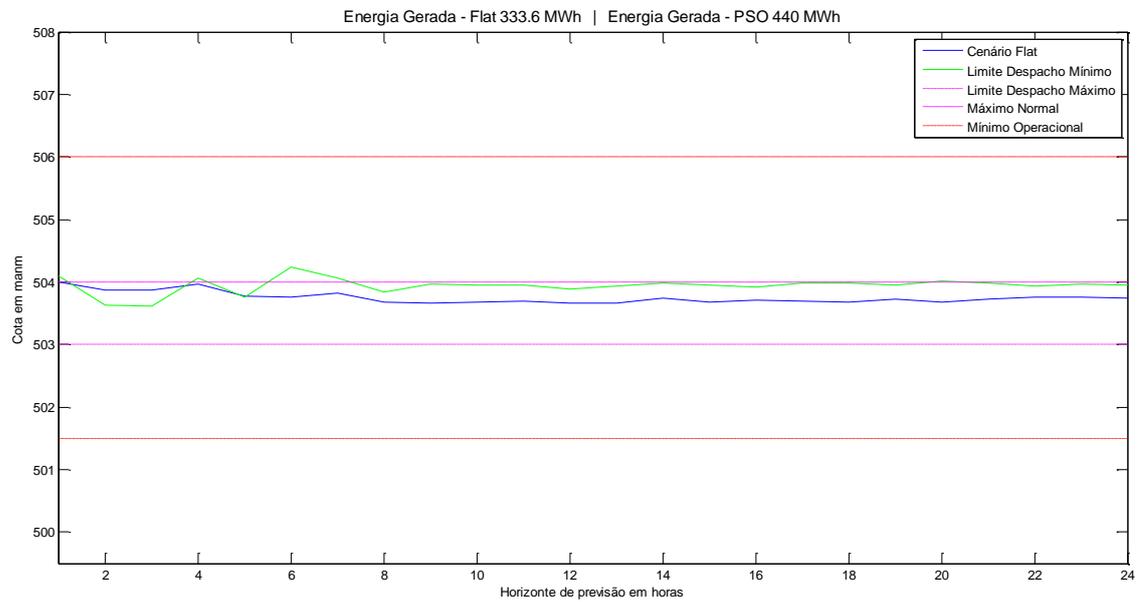


Figura 4.15 – Exemplo de resposta gerada pelo método, simulação 4

## 5. CONCLUSÕES

Este trabalho avaliou métodos para auxílio no despacho diário de centrais hidrelétricas com reservatório de pequena ou nenhuma capacidade de acumulação utilizando a metodologia de Redes Neurais Artificiais para previsão do comportamento limnimétrico de reservatórios e a metodologia de Otimização Por Enxame de Partículas para sugestão do despacho otimizado da Central.

Inicialmente verificou-se a eficiência de modelos para previsão de comportamento limnimétrico em reservatório utilizando Redes Neurais Artificiais. A avaliação se deu de forma prática com a elaboração e implementação de sistema no programa MATLAB®. Os métodos escolhidos para implementação no sistema e posterior avaliação foram: rede neural com inferência Bayesiana com informação de pluviometria de montante e rede neural com inferência Bayesiana baseada no comportamento histórico. A escolha dos métodos baseou-se nos argumentos de [41] e nos estudos realizados em [40] e [57], principalmente.

As variáveis para o sistema de previsão foram o nível do reservatório, também a variável a ser prevista, sendo necessário que o sistema conheça seu histórico para que possa aprender como as demais variáveis impactam em seu comportamento, e que receba seu valor anterior, para prever o sua variação; chuva à montante, com índices pluviométricos medidos em estações de monitoramento a montante do reservatório, que percebam valor de chuva que atinge a área drenada e termine no reservatório; e vazão consumida, que neste modelo foi modelada pela geração da usina. A base de dados foi construída conjugando a informação de diferentes fontes.

Os critérios utilizados para avaliação dos modelos foram os erros médios associados às estimativas em relação ao valor real do comportamento do reservatório para os diferentes períodos climáticos do ano. Essas duas análises se tornam importantes quando da definição da aplicação do método.

Ademais, este estudo propôs um modelo chuva-vazão para previsão do comportamento limnimétrico de reservatórios utilizando Redes Neurais devido à necessidade de realizar melhor planejamento energético em barragens de geração hídrica com objetivo de ganhos potenciais de geração e aumento da segurança da sociedade a partir da melhor regularização dos fluxos de água.

O método desenvolvido foi testado em diferentes situações de treinamento e obteve desempenho satisfatório, atingindo erros percentuais médios da ordem de 0,02% para o horizonte de previsão de 24 horas. A utilização da precipitação trouxe ganhos ao modelo, uma vez que as previsões sem esta informação apresentaram erros 31% superiores que o treinamento Bayesiano com informação de pluviometria.

A partir dos resultados obtidos, é possível verificar que a Rede Neural Artificial desenvolvida foi capaz de acompanhar a tendência dos dados de vazão observados, sendo considerada eficaz para modelar o comportamento limnimétrico do reservatório de Pequenas Centrais Hidrelétricas.

Na continuidade do trabalho foi desenvolvido o método para Auxílio no Planejamento do Despacho Diário de Pequenas Centrais Hidrelétricas, utilizando a RNA treinada e a parametrização de limites operacionais pela metodologia de curvas-guias. A escolha do método para parametrização foi devido aos bons resultados obtidos com a utilização deste método nos trabalhos [68]–[74].

O método funciona através da apresentação de dois cenários distintos de geração – *flat* e otimizado – onde é previsto que não serão extrapoladas as regras operativas definidas. O cenário *flat* foi desenvolvido por se tratar do método mais comum de despacho de centrais hidrelétricas e o cenário otimizado foi construído utilizando a metodologia de Otimização por Enxame de Partículas para verificar os possíveis ganhos de produção com a adoção desta modalidade de despacho.

O método foi testado em diferentes condições climáticas e obteve desempenho satisfatório. Verificou-se que o sistema de previsão e de definição do despacho possui desempenho satisfatório através de diferentes métricas. Inicialmente foi informado ao método o despacho real da base histórica e observou-se que a previsão de comportamento limnimétrico realizada acompanhou satisfatoriamente a tendência do comportamento real. Em seguida foi testada a condição de despacho máxima, isto é, geração máxima da central nas próximas 24 horas, onde pode-se observar que o limite inferior de despacho foi extrapolado, resposta condizente com o comportamento esperado, atestando o método desenvolvido.

A partir da validação do método, foram realizadas diferentes simulações em diferentes períodos climáticos para observar o comportamento das previsões. Para todas as simulações o método apresentou com sucesso cenários de geração *flat* e otimizada, tendo os cenários

otimizados obtido valores de produção energética, em média, 20% superiores ao conceito de despacho *flat*.

A alteração da forma de despacho, da condição *flat* para despacho em base horária, é tecnicamente viável e os recursos necessários para a alteração são os mesmos hoje existentes na usina, sendo necessária apenas uma decisão estratégica para alteração da modalidade de despacho. Assim, o método desenvolvido pode ser facilmente implantando em pequenas centrais a partir da adoção de uma metodologia de despacho diário em base horária, representando ganhos de produção, otimização do uso do recurso hídrico, e potencializando a utilização da mão de obra existente.

Apesar dos bons resultados obtidos, é importante ressaltar que trata-se de um método para previsão de comportamento limnimétrico, que usa como informações de entrada a observação de chuva a montante, o nível atual e o conhecimento adquirido do histórico de operação, para definição do despacho otimizado para a central, assim, ao usar a informação de nível atual, a partir da segunda iteração, esta informação representa a previsão realizada na iteração anterior, o que implica em utilizar um valor previsto como dado de entrada, propagando a possibilidade de erro para as previsões posteriores. Todavia, não são consideradas previsões de precipitação, evitando a necessidade de contratação de serviços de previsão meteorológica visto que são utilizados dados de precipitação realizada de 24 horas atrás.

O tempo de processamento dos cenários otimizados pela metodologia de Enxame de Partículas levou cerca de oito horas para ser realizado. Este tempo de processamento é elevado, mas permite a adoção do método no caso de definição do despacho para o dia subsequente. Entretanto, no caso de necessidade de revisão da previsão de despacho, o tempo de oito horas é impeditivo para verificação e correções do despacho para o próprio dia, sendo um ponto negativo do método. Cabe destacar que toda a metodologia foi desenvolvida em MATLAB® e que este tempo de processamento pode ser reduzido caso o sistema seja implantado utilizando linguagem de programação não interpretada.

### **5.1. RECOMENDAÇÕES PARA TRABALHOS FUTUROS**

Tendo em vista a possibilidade de utilização em tempo real da ferramenta desenvolvida neste trabalho para auxílio na tomada de decisão, uma linha de pesquisa interessante a ser seguida se concentra na redução do tempo de simulação do sistema.

O estudo atingiu resultados satisfatórios, ainda assim o método pode ser refinado, sendo necessários novos modelos para tentar prever diferentes horizontes, por exemplo, de uma semana, com revisão do tamanho da entrada ou trabalhar com diferentes variáveis, como a vazão de montante, que possam auxiliar na previsão deste comportamento.

O tempo de processamento dos cenários otimizados foi em torno de oito horas, o que representa um tempo elevado, sendo impeditivo no caso de verificações de despacho para o dia corrente. Assim, seria relevante a verificação de otimizações do código que conseguissem a redução do tempo de processamento, de forma a potencializar a utilização de método.

Uma questão importante a se estudar é o equacionamento do rendimento dos conjuntos turbina x gerador. No sistema desenvolvido estes valores são calculados indiretamente através do conhecimento aprendido pela Rede Neural de condições históricas reais, que engloba tais informações. Seria interessante, no entanto, estudar como implantar este cálculo de forma direta, e analisar o comportamento do sistema desta forma.

Outro ponto para aprofundamento é a questão do uso máximo da água. Da forma como foi elaborado, o sistema procede a geração de cenários de despacho com o melhor resultado possível, não se preocupando, entretanto, com o que acontecerá no dia seguinte. Será que haverá recurso para o despacho do dia seguinte? E do dia posterior? Este equacionamento segue recaindo em considerações de interligação com estudos de médio e longo prazo, que são as mesmas ponderações levantadas na análise dos estudos do ONS [9] apresentadas na introdução deste estudo.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] “BIG - Banco de Informações de Geração”. [Online]. Disponível em: <http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/OperacaoCapacidadeBrasil.cfm>. [Acessado: 04-fev-2018].
- [2] F. Costa, J. Damazio, e M. Maceira, “Modelos de Previsão Hidrológica Aplicados ao Planejamento da Operação do Sistema Elétrico Brasileiro”, *Rev. Bras. Recur. Hídricos*, vol. 12, nº 3, p. 21–30, 2007.
- [3] S. Soares, “Planejamento de operações de sistema hidrotérmicos”, *Revista Brasileira de Automática*, vol. 1, nº 2, p. 122–123, 1987.
- [4] R. Ballini, S. Soares, e M. G. Andrade, “Previsão de vazões médias mensais usando redes neurais nebulosas”, *Sba Controle Autom. Soc. Bras. Autom.*, vol. 14, nº 3, p. 680–693, set. 2003.
- [5] M. Valença e T. Ludermir, “Multivariate Modelling of Water Resources Time Series using Constructive Neural Networks”, apresentado em V Congresso Brasileiro de Redes Neurais, 2001, p. 2–5.
- [6] G. E. P. Box, G. M. Jenkins, e G. C. Reinsel, *Time series analysis: forecasting and control*, 4th ed. Hoboken, N.J: John Wiley, 2008.
- [7] “PREVIVAZ - Modelos computacionais para previsão de aflúências diárias, semanais e mensais”. [Online]. Disponível em: <http://www.cepel.br/produtos/previvaz-modelos-computacionais-para-previsao-de-afluencias-diarias-semanais-e-mensais.htm>. [Acessado: 22-set-2017].
- [8] V. G. de Oliveira e C. H. R. Lima, “Multiscale streamflow forecasts for the Brazilian hydropower system using bayesian model averaging (BMA)”, *RBRH*, vol. 21, nº 3, p. 618–635, 2016.
- [9] “ONS - Avaliação de Curto Prazo da Operação - Vazões Naturais”. [Online]. Disponível em: [http://apps05.ons.org.br/operacao/previsao\\_vazoes.aspx](http://apps05.ons.org.br/operacao/previsao_vazoes.aspx). [Acessado: 22-ago-2017].
- [10] G. Castanharo *et al.*, “Previsão de Vazões na Bacia do Rio Iguaçu Baseada no Modelo SMAP e com Incorporação de Informações de Precipitação”, *Rev. Bras. Recur. Hídricos*, vol. 12, nº 3, p. 57–68, 2007.
- [11] Bravo J. M., Paz A. R., Collischonn W., Uvo C. B., Pedrollo O. C., e Chou S. C., “Incorporating Forecasts of Rainfall in Two Hydrologic Models Used for Medium-Range Streamflow Forecasting”, *J. Hydrol. Eng.*, vol. 14, nº 5, p. 435–445, maio 2009.
- [12] M. Taghi Sattari, K. Yurekli, e M. Pal, “Performance evaluation of artificial neural network approaches in forecasting reservoir inflow”, *Appl. Math. Model.*, vol. 36, nº 6, p. 2649–2657, jun. 2012.

- [13] L. Alfieri, P. Salamon, F. Pappenberger, F. Wetterhall, e J. Thielen, “Operational early warning systems for water-related hazards in Europe”, *Environ. Sci. Policy*, vol. 21, p. 35–49, 2012.
- [14] A. D. Koussis *et al.*, “Flood Forecasts for Urban Basin with Integrated Hydro-Meteorological Model”, *J. Hydrol. Eng.*, vol. 8, n° 1, p. 1–11, jan. 2003.
- [15] G. Napolitano, L. See, B. Calvo, F. Savi, e A. Heppenstall, “A conceptual and neural network model for real-time flood forecasting of the Tiber River in Rome”, *Phys. Chem. Earth Parts ABC*, vol. 35, n° 3–5, p. 187–194, 2010.
- [16] D. Rabuffetti e S. Barbero, “Operational hydro-meteorological warning and real-time flood forecasting: the Piemonte Region case study”, *Hydrol. Earth Syst. Sci.*, vol. 9, n° 4, p. 457–466, 2005.
- [17] C. E. M. Tucci, *Modelos hidrológicos*. Porto Alegre: Editora da UFRGS, 2005.
- [18] N. A. Gershenfeld e A. S. Weigend, “The Future of Time Series: Learning and Understanding”, *St. Fe Inst. Work. Pap.*, jan. 1993.
- [19] Q. Cui, X. Wang, C. Li, Y. Cai, e P. Liang, “Improved Thomas–Fiering and wavelet neural network models for cumulative errors reduction in reservoir inflow forecast”, *J. Hydro-Environ. Res.*, vol. 13, p. 134–143, dez. 2016.
- [20] A. Elshorbagy, S. P. Simonovic, e U. S. Panu, “Performance Evaluation of Artificial Neural Networks for Runoff Prediction”, *J. Hydrol. Eng.*, vol. 5, n° 4, p. 424–427, out. 2000.
- [21] T. Egawa, K. Suzuki, Y. Ichikawa, T. Iizaka, T. Matsui, e Y. Shikagawa, “A water flow forecasting for dam using neural networks and regression models”, apresentado em Power and Energy Society General Meeting, Detroit, MI, USA, 2011, p. 1–6.
- [22] A. Y. Shamseldin, “Application of a neural network technique to rainfall-runoff modelling”, *J. Hydrol.*, vol. 199, n° 3–4, p. 272–294, 1997.
- [23] G. Zhang, B. E. Patuwo, e M. Y. Hu, “Forecasting with artificial neural networks:: The state of the art”, *Int. J. Forecast.*, vol. 14, n° 1, p. 35–62, 1998.
- [24] K. Hsu, H. V. Gupta, e S. Sorooshian, “Artificial neural network modeling of the rainfall-runoff process”, *Water Resour. Res.*, vol. 31, n° 10, p. 2517–2530, 1995.
- [25] A. S. Tokar e P. A. Johnson, “Rainfall-runoff modeling using artificial neural networks”, *J. Hydrol. Eng.*, vol. 4, n° 3, p. 232–239, 1999.
- [26] S.-C. Chang, C.-H. Chen, I.-K. Fong, e P. B. Luh, “Hydroelectric generation scheduling with an effective differential dynamic programming algorithm”, *IEEE Trans. Power Syst.*, vol. 5, n° 3, p. 737–743, 1990.

- [27] S. M. Amado e C. C. Ribeiro, “Short-term generation scheduling of hydraulic multi-reservoir multi-area interconnected systems”, *IEEE Trans. Power Syst.*, vol. 2, n° 3, p. 758–763, 1987.
- [28] H. Brannlund, D. Sjelvgren, e J. A. Bubenko, “Short term generation scheduling with security constraints”, *IEEE Trans. Power Syst.*, vol. 3, n° 1, p. 310–316, 1988.
- [29] F. Zhuang e F. D. Galiana, “Towards a more rigorous and practical unit commitment by Lagrangian relaxation”, *IEEE Trans. Power Syst.*, vol. 3, n° 2, p. 763–773, 1988.
- [30] G.-X. Luo, H. Habibollahzadeh, e A. Semlyen, “Short-term hydro-thermal dispatch detailed model and solutions”, *IEEE Trans. Power Syst.*, vol. 4, n° 4, p. 1452–1462, 1989.
- [31] T. Ohishi, S. Soares, e M. de Carvalho, “A short term hydrothermal scheduling approach for dominantly hydro systems”, *IEEE Trans. Power Syst.*, vol. 6, n° 2, p. 637–643, 1991.
- [32] M. Heydari, F. Othman, e M. Taghieh, “Optimization of Multiple and Multipurpose Reservoir System Operations by Using Matrix Structure (Case Study: Karun and Dez Reservoir Dams)”, *PLOS ONE*, vol. 11, n° 6, p. e0156276, jun. 2016.
- [33] M.-Y. Tu, N.-S. Hsu, e W. W.-G. Yeh, “Optimization of Reservoir Management and Operation with Hedging Rules”, *J. Water Resour. Plan. Manag.*, vol. 129, n° 2, p. 86–97, mar. 2003.
- [34] A. Ahmad, A. El-Shafie, S. F. M. Razali, e Z. S. Mohamad, “Reservoir Optimization in Water Resources: a Review”, *Water Resour. Manag.*, vol. 28, n° 11, p. 3391–3405, set. 2014.
- [35] L. Liu, L. Fu, Y. Zhang, e W. Zhu, “An efficient approach for power system economic dispatch with non-convex objectives and constraints”, 2017, p. 1267–1272.
- [36] J. Nanda, D. P. Kothari, e S. C. Srivastava, “New optimal power-dispatch algorithm using Fletcher’s quadratic programming method”, *IEE Proc. C Gener. Transm. Distrib.*, vol. 136, n° 3, p. 153, 1989.
- [37] A. G. Bakirtzis, P. N. Biskas, C. E. Zoumas, e V. Petridis, “Optimal power flow by enhanced genetic algorithm”, *IEEE Trans. Power Syst.*, vol. 17, n° 2, p. 229–236, maio 2002.
- [38] P. Leite, A. F. M. Carneiro, e A. P. L. F. Carvalho, “Hybrid Genetic Algorithm Applied to the Determination of the Optimal Operation of Hydrothermal Systems”, 2006, p. 15–15.
- [39] L. Ostadrahimi, M. A. Mariño, e A. Afshar, “Multi-reservoir Operation Rules: Multi-swarm PSO-based Optimization Approach”, *Water Resour. Manag.*, vol. 26, n° 2, p. 407–427, jan. 2012.
- [40] L. Gomes, S. Montenegro, e M. ValençA, “Modelo Baseado na Técnica de Redes Neurais para Previsão de Vazões na Bacia do Rio São Francisco”, *Rev. Bras. Recur. Hídricos*, vol. 15, n° 1, p. 5–15, 2010.

- [41] O. Pedrollo, “Previsão Hidrológica de Curto Prazo com chuvas efetivas Determinadas pela Função Sigmóide.”, *Rev. Bras. Recur. Hídricos*, vol. 4, n° 2, p. 19–30, 1999.
- [42] T. Sáfadi, “Uso de séries temporais na análise de vazão de água na represa de furnas”, *Ciênc. E Agrotecnologia*, vol. 28, n° 1, p. 142–148, fev. 2004.
- [43] M. I. F. Ferraz, T. Sáfadi, e G. Lage, “Uso de modelos de séries temporais na previsão de séries de precipitação pluviais mensais no município de Lavras - MG.”, *Revista Brasileira de Agrometeorologia, Santa Maria, RS*, vol. 7, n° 2, p. 259–267, 1999.
- [44] M. Ashrafi, L. H. C. Chua, C. Quek, e X. Qin, “A fully-online Neuro-Fuzzy model for flow forecasting in basins with limited data”, *J. Hydrol.*, vol. 545, p. 424–435, fev. 2017.
- [45] G. B. Humphrey, M. S. Gibbs, G. C. Dandy, e H. R. Maier, “A hybrid approach to monthly streamflow forecasting: Integrating hydrological model outputs into a Bayesian artificial neural network”, *J. Hydrol.*, vol. 540, p. 623–640, set. 2016.
- [46] T. Lohmann, A. S. Hering, e S. Rebennack, “Spatio-temporal hydro forecasting of multireservoir inflows for hydro-thermal scheduling”, *Eur. J. Oper. Res.*, vol. 255, n° 1, p. 243–258, nov. 2016.
- [47] A. G. Evsukoff, M. Cataldi, e B. S. L. P. de Lima, “A multi-model approach for long-term runoff modeling using rainfall forecasts”, *Expert Syst. Appl.*, vol. 39, n° 5, p. 4938–4946, abr. 2012.
- [48] D. E. Rumelhart, G. E. Hinton, e R. J. Williams, “Learning representations by back-propagating errors”, *Nature*, vol. 323, n° 6088, p. 533–536, out. 1986.
- [49] S. S. Haykin, *Neural networks and learning machines*, 3rd ed. New York: Prentice Hall, 2009.
- [50] L. G. Fernandes, “Previsão de Séries de Tempo: Redes neurais artificiais e modelos estruturais”, in *Pesquisa e planejamento econômico*, vol. 26, Instituto de Planejamento Econômico e Social., 1996, p. 253–276.
- [51] C. C. Santos, “Modelagem hidrológica utilizando redes neurais artificiais em bacias urbanas”, Dissertação de Mestrado, USP, São Paulo, 2001.
- [52] J. Anmala, B. Zhang, e R. S. Govindaraju, “Comparison of ANNs and empirical approaches for predicting watershed runoff”, *J. Water Resour. Plan. Manag.*, vol. 126, n° 3, p. 156–166, 2000.
- [53] R. Hecht-Nielsen, *Neurocomputing*. Reading, Mass: Addison-Wesley Pub. Co, 1990.
- [54] I. Saraiva, W. Fernandes, e M. Naghettini, “Simulação Hidrológica Mensal em Bacias Hidrográficas sem Monitoramento Fluviométrico”, *Rev. Bras. Recur. Hídricos*, vol. 16, n° 1, p. 115–125, 2011.

- [55] P. J. Block, F. A. Souza Filho, L. Sun, e H. Kwon, “A streamflow forecasting framework using multiple climate and hydrological models”, *JAWRA J. Am. Water Resour. Assoc.*, vol. 45, n° 4, p. 828–843, 2009.
- [56] L. F. Gomes, “Previsão de vazões naturais diárias ao reservatório de três marias usando a técnica de redes neurais”, Dissertação, Mestrado, Universidade Federal de Pernambuco, Recife, 2006.
- [57] M. Cataldi, C. Machado, J. Gomes, J. Bustamante, L. Guilhon, e S. Chou, “Análise das Previsões de Precipitação Obtidas com a Utilização do Modelo Eta como Insumo para Modelos de Previsão Semanal de Vazão Natural”, *Rev. Bras. Recur. Hídricos*, vol. 12, n° 3, p. 5–12, 2007.
- [58] J. Crespo e E. Mora, “Drought estimation with neural networks”, *Adv. Eng. Softw.*, vol. 18, n° 3, p. 167–170, 1993.
- [59] Y. Bai, Z. Chen, J. Xie, e C. Li, “Daily reservoir inflow forecasting using multiscale deep feature learning with hybrid models”, *J. Hydrol.*, vol. 532, p. 193–206, jan. 2016.
- [60] M. E. Banihabib, A. Ahmadian, e F. S. Jamali, “Hybrid DARIMA-NARX model for forecasting long-term daily inflow to Dez reservoir using the North Atlantic Oscillation (NAO) and rainfall data”, *GeoResJ*, vol. 13, p. 9–16, jun. 2017.
- [61] F. M. Fan, V. A. Siqueira, W. Collischonn, e S. C. Chou, “Ensemble flood forecasting based on operational forecasts of the regional Eta EPS in the Taquari-Antas basin”, *RBRH*, vol. 21, n° 3, p. 587–602, set. 2016.
- [62] G. S. Mohor, D. A. Rodriguez, J. Tomasella, e J. L. Siqueira Júnior, “Exploratory analyses for the assessment of climate change impacts on the energy production in an Amazon run-of-river hydropower plant”, *J. Hydrol. Reg. Stud.*, vol. 4, p. 41–59, set. 2015.
- [63] M. T. Nóbrega, W. Collischonn, C. E. M. Tucci, e A. R. Paz, “Uncertainty in climate change impacts on water resources in the Rio Grande Basin, Brazil”, *Hydrol. Earth Syst. Sci.*, vol. 15, n° 2, p. 585–595, fev. 2011.
- [64] J. L. S. Júnior, J. Tomasella, e D. A. Rodriguez, “Impacts of future climatic and land cover changes on the hydrological regime of the Madeira River basin”, *Clim. Change*, vol. 129, n° 1–2, p. 117–129, mar. 2015.
- [65] D. P. Loucks, E. van Beek, e J. R. Stedinger, *Water resources systems planning and management: an introduction to methods, models and applications*. Paris: UNESCO, 2005.
- [66] L. . Mays e Y.-K. Tung, *Hydrosystems engineering and management*. Highlands Ranch, CO: Water Resources Publications, LLC, 2002.
- [67] R. A. Wurbs, *Modeling and analysis of reservoir system operations*. Upper Saddle River, NJ: Prentice Hall PTR, 1996.
- [68] L. Chen, “Real coded genetic algorithm optimization of long term reservoir operation”, *J. Am. Water Resour. Assoc.*, vol. 39, n° 5, p. 1157–1165, out. 2003.

- [69] C. Tung, S. Hsu, C.-M. Liu, e J.-S. Li, “Application of the genetic algorithm for optimizing operation rules of the liyutan reservoir in taiwan1”, *JAWRA J. Am. Water Resour. Assoc.*, vol. 39, n° 3, p. 649–657, jun. 2003.
- [70] F.-J. Chang, L. Chen, e L.-C. Chang, “Optimizing the reservoir operating rule curves by genetic algorithms”, *Hydrol. Process.*, vol. 19, n° 11, p. 2277–2289, jul. 2005.
- [71] R. Oliveira e D. P. Loucks, “Operating rules for multireservoir systems”, *Water Resour. Res.*, vol. 33, n° 4, p. 839–852, abr. 1997.
- [72] I. Nalbantis e D. Koutsoyiannis, “A parametric rule for planning and management of multiple-reservoir systems”, *Water Resour. Res.*, vol. 33, n° 9, p. 2165–2177, set. 1997.
- [73] D. Koutsoyiannis, A. Efstratiadis, e G. Karavokiros, “A decision support tool for the management of multi-reservoir systems”, *J. Am. Water Resour. Assoc.*, vol. 38, n° 4, p. 945–958, ago. 2002.
- [74] A. Arce, “Um modelo de otimização do despacho de máquinas em usinas hidrelétricas.”, Dissertação (Mestrado), UNICAMP, 1999.
- [75] G. B. Sheble e G. N. Fahd, “Unit commitment literature synopsis”, *IEEE Trans. Power Syst.*, vol. 9, n° 1, p. 128–135, fev. 1994.
- [76] L. M. Rux, “An incremental economic dispatch method for cascaded hydroelectric power plants”, *IEEE Trans. Power Syst.*, vol. 8, n° 3, p. 1266–1273, ago. 1993.
- [77] R.-H. Liang, “Scheduling of hydroelectric generations using artificial neural networks”, *IEE Proc. - Gener. Transm. Distrib.*, vol. 141, n° 5, p. 452, 1994.
- [78] R.-H. Liang e Y.-Y. Hsu, “Short-term hydro-scheduling using Hopfield neural network”, *IEE Proc. - Gener. Transm. Distrib.*, vol. 143, n° 3, p. 269, 1996.
- [79] O. Nilsson e D. Sjelvgren, “Hydro unit start-up costs and their impact on the short term scheduling strategies of Swedish power producers”, *IEEE Trans. Power Syst.*, vol. 12, n° 1, p. 38–44, fev. 1997.
- [80] Kit Po Wong, Yin Wa Wong, e Yunbei Yu, “A simulated annealing approach to short-term hydro scheduling”, 1993, p. 323–328.
- [81] S. Soares e C. T. Salmazo, “Minimum loss predispach model for hydroelectric power systems”, *IEEE Trans. Power Syst.*, vol. 12, n° 3, p. 1220–1228, ago. 1997.
- [82] C. Lyra e L. R. M. Ferreira, “A multiobjective approach to the short-term scheduling of a hydroelectric power system”, *IEEE Trans. Power Syst.*, vol. 10, n° 4, p. 1750–1755, nov. 1995.
- [83] E. C. Finardi e E. L. da Silva, “Unit commitment of single hydroelectric plant”, *Electr. Power Syst. Res.*, vol. 75, n° 2–3, p. 116–123, ago. 2005.

- [84] D. P. Lettenmaier e E. F. Wood, “Hydrologic Forecasting”, in *Handbook of hydrology*, vol. 1, McGraw-Hill New York, 1993.
- [85] M. A. Tafner e M. de Xerez, *Redes neurais artificiais: introdução e princípios de neurocomputação*. Blumenau: EKO : Ed. da FURB, 1996.
- [86] A. A. Gorni, “Redes Neurais Artificiais-Uma Abordagem revolucionária em Inteligência Artificial”, *Micro Sist. São Paulo*, 1993.
- [87] C. Loesch e S. T. Sari, *Redes neurais artificiais: fundamentos e modelos*. Blumenau: Ed. da FURB, 1996.
- [88] Z. L. Kovács, *Redes neurais artificiais: fundamentos e aplicações*. São Paulo: Ed. Livraria da Física, 2002.
- [89] C. de O. Galvão, *Sistemas inteligentes aplicações a recursos hídricos e ciências ambientais.*, vol. 7. Porto Alegre: UFRGS: ABRH, 1999.
- [90] C. M. Bishop, *Pattern recognition and machine learning*. New York: Springer, 2006.
- [91] E. H. Tito, G. Zaverucha, M. Vellasco, e M. Pacheco, “Bayesian neural networks for electric load forecasting”, 1999, vol. 1, p. 407–411.
- [92] V. H. Ferreira, “Desenvolvimento de Modelos Neurais Autônomos para Previsão de Carga Elétrica”, Tese Doutorado, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2008.
- [93] C. Bishop, “Exact calculation of the Hessian matrix for the multilayer perceptron”, 1992.
- [94] K. Thirumalaiah e M. C. Deo, “River Stage Forecasting Using Artificial Neural Networks”, *J. Hydrol. Eng.*, vol. 3, n° 1, p. 26–32, jan. 1998.
- [95] N. Sajikumar e B. S. Thandaveswara, “A non-linear rainfall–runoff model using an artificial neural network”, *J. Hydrol.*, vol. 216, n° 1–2, p. 32–55, mar. 1999.
- [96] Xin Yao, “Evolving artificial neural networks”, *Proc. IEEE*, vol. 87, n° 9, p. 1423–1447, set. 1999.
- [97] J. Kennedy e W. M. Spears, “Matching algorithms to problems: an experimental test of the particle swarm and some genetic algorithms on the multimodal problem generator”, 1998, p. 78–83.
- [98] G. Pessin e F. Osório, “Otimização por Enxame de Partículas aplicado à formação e atuação de grupos robóticos”, *Scientia*, vol. 20, n° 2, p. 94–106, dez. 2009.
- [99] J. Robinson e Y. Rahmat-Samii, “Particle Swarm Optimization in Electromagnetics”, *IEEE Trans. Antennas Propag.*, vol. 52, n° 2, p. 397–407, fev. 2004.

- [100] A. Pavelka e A. Procházka, “Algorithms for initialization of neural network weights”, apresentado em Proceedings of the 12th Annual Conference, MATLAB, 2004, p. 453–459.