

**UNIVERSIDADE FEDERAL DE ALFENAS
DEPARTAMENTO DE CIÊNCIAS EXATAS
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

Mariana Dehon Costa e Lima

**ANÁLISE DA UTILIZAÇÃO DA ENERGIA NATURAL
AFLUENTE PARA PREVISÃO DE VAZÕES AFLUENTES
MENSAIS VIA SUPPORT VECTOR MACHINES**

Alfenas, 29 de novembro de 2011.

UNIVERSIDADE FEDERAL DE ALFENAS
DEPARTAMENTO DE CIÊNCIAS EXATAS
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

**ANÁLISE DA UTILIZAÇÃO DA ENERGIA NATURAL
AFLUENTE PARA PREVISÃO DE VAZÕES AFLUENTES
MENSIS VIA SUPPORT VECTOR MACHINES**

Mariana Dehon Costa e Lima

Monografia apresentada ao Curso de Bacharelado em
Ciência da Computação da Universidade Federal de
Alfenas como requisito parcial para obtenção do Título de
Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Ricardo Menezes Salgado

Alfenas, 29 de novembro de 2011.

Mariana Dehon Costa e Lima

**ANÁLISE DA UTILIZAÇÃO DA ENERGIA NATURAL
AFLUENTE PARA PREVISÃO DE VAZÕES AFLUENTES
MENSAIS VIA SUPPORT VECTOR MACHINES**

A Banca examinadora abaixo-assinada aprova a monografia apresentada como parte dos requisitos para obtenção do título de Bacharel em Ciência da Computação pela Universidade Federal de Alfenas.

Prof. Dr. Denismar Alves Nogueira

Universidade Federal de Alfenas

Prof. Humberto César Brandão de Oliveira

Universidade Federal de Alfenas

Prof. Dr. Ricardo Menezes Salgado (Orientador)

Universidade Federal de Alfenas

Alfenas, 29 de novembro de 2011.

À minha avó Nininha.

AGRADECIMENTO

Agradeço aos meus pais por todo apoio que tive e por serem os maiores incentivadores de toda minha vida acadêmica e sem os quais eu não teria forças ou condições necessárias para concluir uma graduação ou realizar este trabalho. Além dos meus pais, agradeço à toda minha família, que de uma forma ou outra ajudou, incentivou e torceu por mim. Meus agradecimentos especiais à minha tia Marlene, meu tio Ivan Cleber, minha avó Nininha e meu avô Feliciano. Sem vocês eu nunca conseguiria ter chegado aonde cheguei.

Agradeço a todos meus amigos e em especial ao Júnio César, Ana Luiza e Mateus Drigo que foram presentes, ajudaram e me incentivaram durante a minha graduação. Agradeço ainda à Tatiane, por ter sido o ponto de apoio durante os anos que passei na faculdade. Ela esteve do meu lado nas situações boas, nas ruins e foi a principal responsável por me manter leal, me manter focada e por lembrar-me constantemente do que é importante, do que faz a diferença.

Agradeço ao meu orientador Ricardo Menezes Salgado que foi mais que um orientador e se tornou um ponto de referência para toda a minha vida. Muito obrigada pela paciência, pela compreensão, pelo apoio e por todo o conhecimento transmitido ao passar dos anos. Tudo isso tem um valor inestimável para mim.

Agradeço, enfim, ao LInC (Laboratório de Inteligência Computacional) e aos colegas e amigos que desenvolvi com na graduação e toda a experiência pessoal e profissional que a convivência e o trabalho desenvolveram.

"Não é o cérebro que mais importa, mas sim o que o orienta: o caráter, o coração, a generosidade e as ideias progressivas."
Dostoyevsky (Ryan & Bohlin, 1999))

RESUMO

Este trabalho propõe uma metodologia para a previsão de valores da série de vazões afluentes de cada usina de um subsistema de hidrelétricas através da série agregada de Energia Natural Afluente (ENA) e sua desagregação. É feita a previsão de Um até Doze Passos Atrás utilizando a técnica de previsão *Support Vector Machines* (SVM). A aplicação da metodologia é feita em cima das usinas de Furnas, Mascarenhas de Moraes (Peixoto), Marimbondo e Água Vermelha da Bacia do Rio Grande (Brasil) e a sua eficiência é medida através da análise da previsão da série de ENA com a previsão da série histórica de vazão individual. Ao verificar os resultados, foi possível afirmar que a previsão utilizando a série agregada ENA via SVM tornou-se eficiente e em alguns casos com erros inferiores aos encontrados utilizando a série de vazões histórica e usando técnicas convencionais como Redes Neurais Artificiais tipo *Multilayer Perceptron* (MLP).

Palavras-Chave: série de vazões afluentes, energia natural afluente, previsão de vazão, *support vector machines*, regressão.

ABSTRACT

This work proposes a methodology for predicting the streamflow series values from each plant of a hydroelectric subsystem through the Affluent Natural Energy (ENA) aggregate series and its breakdown. Predications are made of up to twelve feet behind and the forececast technique used is the Support Vector Machines (SVM). The application of the methodology is made on Furnas, Mascarenhas de Moraes (Peixoto), Marimbondo and Água Vermelha that belongs of the Basin of the Rio Grande (Brazil) and its efficiency is measured by analyzing the ENA series forecasting with forecasting flow series. When checking the results was possible to affirm that the aggregate ENA'a series prediction using SVM has become effective and in some cases with lower errors than those found using the historical serial flow and using conventional techniques such as Artificial Neural Networks of the kind Multilayer Perceptron (MLP).

Keywords: forecasting streamflow series, affluent natural energy, series prediction, support vector machines, regression.

LISTA DE FIGURAS

FIGURA 1 - SÉRIE HISTÓRICA DE VAZÕES AFLUENTES DA HIDRELÉTRICA DE FURNAS DOS ANOS DE 1990 ATÉ 2005.....	32
FIGURA 2 - SÉRIE ENA PARA O SUBSISTEMA FURNAS E PEIXOTO NO PERÍODO DE 1990 ATÉ 2005.....	36
FIGURA 3 - FLUXOGRAMA DE APRENDIZADO E PREVISÃO DOS ALGORITMOS DO TIPO APRENDIZADO SUPERVISIONADO.	38
FIGURA 4 - DIMENSÃO VC. FONTE: SEMOLINI, 2002.	40
FIGURA 5 - MARGEM P E OS VETORES DE SUPORTE. FONTE: LIMA, 2002.....	42
FIGURA 6 - FUNÇÃO DE PERDA E -INSENSITIVA. FONTE: FERRO, 2007.	44
FIGURA 7 - CONCEITO DE MARGEM NO SVR. FONTE: SMOLA, 2002.....	45
FIGURA 8 - FLUXOGRAMA DE BUSCA EXAUSTIVA.	48
FIGURA 9 - FLUXOGRAMA DE CÁLCULO E DESAGREGAÇÃO DA SÉRIE DE ENA.....	50
FIGURA 10 - FLUXOGRAMA DE PREVISÃO UM PASSO ATRÁS.	51
FIGURA 11 - FLUXOGRAMA DE PREVISÃO ATÉ DOZE PASSOS ATRÁS.	52
FIGURA 12 - DADOS BRUTOS DOS AOS DE 1996 A 2010 DE VAZÃO PARA AS USINAS DE FURNAS, MASCARENHAS DE MORAES (PEIXOTO), MARIMBONDO E AGUA VERMELHA	53
FIGURA 13 - DIAGRAMA ESQUEMÁTICO DA BACIA DO RIO GRANDE (OPERADOR NACIONAL DO SISTEMA, 2011)	54
FIGURA 14 - SÉRIE DE ENA CALCULADA PARA O SUBSISTEMA PROPOSTO.	55
FIGURA 15 - SÉRIE DA ENA HISTÓRICA COMPARADA COM A PREVISÃO UM PASSO ATRÁS FEITAS PELAS TÉCNICAS SVM E RNA	57
FIGURA 16- MÉDIA, ASSIMETRIA, CURTOSE, DESVIO-PADRÃO, MÁXIMO, MÍNIMO, MEDIANA E COEFICIENTE DE VARIAÇÃO ENTRE AS SÉRIE REAL E AS SÉRIES PREVISTAS DE ENA PARA UM E DOZE PASSOS ATRÁS.....	60
FIGURA 17 - RSME DA PREVISÃO DA SÉRIE DE ENA DESAGREGADA EM RELAÇÃO À PREVISÃO DE VAZÃO DA USINA DE FURNAS	62
FIGURA 18 - RSME DA PREVISÃO DA SÉRIE DE ENA DESAGREGADA EM RELAÇÃO À PREVISÃO DE VAZÃO DA USINA DE MASCARENHAS DE MORAES (PEIXOTO).....	63
FIGURA 19 - RSME DA PREVISÃO DA SÉRIE DE ENA DESAGREGADA EM RELAÇÃO À PREVISÃO DE VAZÃO DA USINA DE MARIMBONDO	64
FIGURA 20 - RSME DA PREVISÃO DA SÉRIE DE ENA DESAGREGADA EM RELAÇÃO À PREVISÃO DE VAZÃO DA USINA DE ÁGUA VERMELHA.....	65
FIGURA 21 - RSME DA PREVISÃO DA SÉRIE SINTÉTICA DE ENA DESAGREGADA EM RELAÇÃO À PREVISÃO DE VAZÃO DA USINA DE MARIMBONDO.....	71

LISTA DE TABELAS

TABELA 1 – TIPOS MAIS COMUNS DE <i>KERNELS</i> . FONTE: LORENA ET AL., 2007.....	44
TABELA 2 - PARÂMETROS UTILIZADOS NA BUSCA EXAUSTIVA DO SVM	48
TABELA 3 - CONJUNTO DE TREINAMENTO (MÊS X - DELAY 1)	50
TABELA 4 - PRODUTIVIDADE À 65% DE CADA USINA DA INSTÂNCIA DE TESTE	55
TABELA 5 – PRINCIPAIS VARIÁVEIS ESTATÍSTICAS PARA A ENA E VAZÕES DO SUBSISTEMA.	55
TABELA 6 – ERRO MAPE EM PORCENTAGEM DAS PREVISÕES UM PASSO ATRÁS E DOZE PASSOS ATRÁS DA INSTÂNCIA DE ENA PROPOSTA.	57
TABELA 7 – VARIÁVEIS ESTATÍSTICAS PARA A PREVISÃO DE VAZÃO DA USINA DE FURNAS.....	67
TABELA 8 - VARIÁVEIS ESTATÍSTICAS PARA A PREVISÃO DE VAZÃO DA USINA DE PEIXOTO.....	67
TABELA 9 - VARIÁVEIS ESTATÍSTICAS PARA A PREVISÃO DE VAZÃO DA USINA DE MARIMBONDO	68
TABELA 10 - VARIÁVEIS ESTATÍSTICAS PARA A PREVISÃO DE VAZÃO DA USINA DE ÁGUA VERMELHA.	69

LISTA DE ABREVIACÕES

SVC	<i>Support Vector Classification</i>
SVR	<i>Support Vector Regression</i>
AM	Aprendizado de Máquina
NN	<i>Nearest Neighbor</i>
Teoria VC	Teoria de Vapnik-Chervonenkis
SRM	<i>Structural Risk Minimization</i>
ENA	Energia Natural Afluyente
ERM	<i>Empirical Risk Minimization</i>
RNA	Redes Neurais Artificiais
MLT	Média Histórica
MLP	<i>Multilayer Perceptron</i>
DP	<i>Desvio-Padrão</i>
RMSE	Raiz Quadrada do Erro Quadrático Médio
MAPE	Erro Quadrático Médio
SVM	<i>Support Vector Machines</i>
ONS	Operador Nacional do Sistema Elétrico

SUMÁRIO

1 INTRODUÇÃO	25
1.1 JUSTIFICATIVA E MOTIVAÇÃO	26
1.2 PROBLEMATIZAÇÃO	27
1.3 OBJETIVOS	28
1.3.1 Gerais	28
1.3.2 Específicos	28
1.4 ORGANIZAÇÃO DA MONOGRAFIA	28
2 DESCRIÇÃO DO PROBLEMA	31
2.1 CONSIDERAÇÕES INICIAIS	31
2.2 PREVISÃO DE VAZÕES NO SETOR ELÉTRICO	31
2.3 ENERGIA NATURAL AFLUENTE	35
3 A TÉCNICA <i>SUPPORT VECTOR MACHINES</i>	37
3.1 APRENDIZADO SUPERVISIONADO	37
3.2 A TÉCNICA	38
3.3 DIMENSÃO DE VAPNIK-CHERVONENKIS (VC)	39
3.4 MINIMIZAÇÃO DO RISCO ESTRUTURAL (SRM)	40
3.5 <i>SUPPORT VECTOR CLASSIFICATION</i> (SVC)	41
3.6 FUNÇÕES KERNEL	43
3.7 <i>SUPPORT VECTOR REGRESSION</i> (SVR)	44
4 METODOLOGIA PROPOSTA	47
4.1 CONSIDERAÇÕES INICIAIS	47
4.2 IDENTIFICAÇÃO E AJUSTE	47
4.3 CONJUNTO DE TREINAMENTO E TRATAMENTO DE DADOS	49
4.4 PREVISÃO UM PASSO ATRÁS	51
4.5 PREVISÃO ATÉ DOZE PASSOS ATRÁS	51
5 RESULTADOS	53
5.1 INSTÂNCIA DE TESTE E ANÁLISE DOS DADOS	53
5.2 RESULTADOS OBTIDOS	56
5.3 COMPARAÇÃO ESTATÍSTICA ENTRE AS SÉRIES	58
5.4 DESEMPENHO DA PREVISÃO ENA EM RELAÇÃO À VAZÃO AFLUENTE	61
5.5 PREVISÃO UTILIZANDO SÉRIE SINTÉTICA	70
6 CONSIDERAÇÕES FINAIS	73
7 REFERÊNCIAS BIBLIOGRÁFICAS	77

1

Introdução

Neste capítulo é apresentada uma visão geral sobre o tema tratado neste trabalho. Na Seção 1.1 são apresentadas a justificativa e a motivação do trabalho. Na Seção 1.2 é discutido o problema que envolve o tema proposto. Na Seção 1.3 são mostrados quais são os objetivos que este trabalho se propõe a realizar.

A natureza tem continuamente cumprido um importante papel, fornecendo subsídios indispensáveis à sobrevivência e sendo um dos principais propulsores do desenvolvimento humano. Dentre os inúmeros recursos naturais disponíveis, a água destaca-se como um elemento primordial. O conhecimento a respeito da disponibilidade deste recurso é essencial devido às suas várias aplicações, dentre as quais é possível destacar: abastecimento, sistemas de irrigação, navegação, pesca, recreação, transporte de resíduos e geração de energia elétrica entre outros.

Em um contexto geral o homem busca conhecer, de forma empírica, como as complexas interações do meio ambiente se desenvolvem. Para este fim, o caminho adotado tem sido a representação de fenômenos físicos por meio de modelos matemáticos e algoritmos computacionais. No estudo dos recursos hídricos, discute-se e aprimora-se a cada instante o conhecimento sobre os diferentes fenômenos naturais que constituem o ciclo hidrológico. Uma das formas de analisar o comportamento hídrico é através de métodos teóricos, que visam modelar os processos hidrológicos através de equações matemáticas que permitam simular o comportamento da natureza determinando o estado das diferentes variáveis hidrológicas a cada instante.

A elaboração de modelos para representar fenômenos físicos ampliou o horizonte dos estudos ao permitir simulações de diferentes cenários aplicados a um sistema existente. Esse fato, do ponto de vista do aproveitamento dos recursos hídricos, trouxe enormes vantagens como a previsão de fenômenos hidrológicos importantes, facilitando a análise dos seus impactos e consequências com maior

propriedade. A simulação de um modelo/método matemático sintetiza o passado, presente e o futuro de forma aproximada apresentando diferenças entre a realidade dos eventos observados e estimados. Estas diferenças representam as incertezas dos modelos e, uma forma de minimizá-las é selecionar o modelo com base em critérios físicos do sistema. Esses critérios podem ser representados por expressões matemáticas ou matemática-estatísticas ou estocásticas.

Sendo assim, procura-se sintetizar esse conhecimento através de modelos que possam quantificar, qualificar e gerenciar a água disponível no ciclo hidrológico. Neste sentido, o planejamento dos recursos hídricos ganha dimensão fundamental, pois possibilita a criação de diretrizes a serem seguidas que proporcionam melhor aproveitamento, controle e conservação da água em um contexto geral.

1.1 Justificativa e Motivação

Além da importância da água para a vida em geral, existe também a importância econômica, principalmente para o Brasil, que possui grande parte da sua energia elétrica produzida pelas usinas hidrelétricas. Devido à complexidade dos fenômenos hídricos, existe a necessidade de estabelecer modelos capazes de representar com nível de precisão satisfatório o comportamento da água. No caso de usinas hidrelétricas, por exemplo, a água proveniente da chuva direciona-se aos rios que, por sua vez, alimentam os reservatórios dessas usinas que recebem diferentes regimes pluviométricos trazendo também diferentes respostas de vazão, o que reflete diretamente na operação do reservatório de uma usina.

No mesmo raciocínio é necessário avaliar comportamento hidrológico para avaliar o impacto da construção de obras, em particular, a construção de novas usinas geradoras de eletricidade. Analogamente, esse tipo de estudo é importante às usinas para aprimorar suas regras de operação. Para o dimensionamento e operação desses sistemas de reservatórios normalmente submetidos a usos múltiplos e concorrentes (abastecimento humano, irrigação, produção de energia, entre outros) geralmente utiliza-se de modelos determinísticos chuva-vazão e/ou

de modelos de geração estocástica de vazão (Freitas, 1998), dependendo principalmente da disponibilidade de dados.

Entretanto, de um modo geral, análises estatísticas relacionadas às vazões são condicionadas a cada usina individualmente, demandando um grande tempo computacional e uma não generalização do problema.

1.2 Problematização

Decisões tomadas no gerenciamento de sistemas de recursos hídricos são geralmente fundamentadas na análise de registros históricos de vazão afluente que variam de usina para usina. Entretanto, a grande quantidade de usinas dispostas em uma bacia ou subsistema aumenta drasticamente o custo computacional necessário para a previsão de cada uma isoladamente.

Uma possível solução para este problema é a agregação das vazões através de uma série derivada, como a série de Energia Natural Afluente (ENA) que é a soma das energias naturais afluentes a todas as usinas de cada subsistema, ou seja, a ENA de uma usina é o produto da vazão natural afluente desta usina pela sua produtividade média (Ramos, 2011).

Neste sentido, este trabalho foca a resposta da seguinte questão: A previsão da série de Energia Natural Afluente é capaz de diminuir o custo computacional gasto para a previsão de um subsistema e obter resultados satisfatórios quando comparada à previsão de série de vazão afluente utilizando a técnica *Support Vector Machines* (SVM)?

1.3 Objetivos

1.3.1 Gerais

O principal objetivo desse trabalho é realizar uma análise da utilização da série de Energia Natural Afluente para a previsão de vazões e observar seu desempenho utilizando a técnica *Support Vector Machines*.

1.3.2 Específicos

- Realizar a previsão da série de ENA e a desagregação da mesma utilizando *Support Vector Machines*;
- Comparar o desempenho da previsão via SVM da série de ENA com a série de vazões afluentes em um subsistema de usinas;
- Comparar os resultados obtidos via SVMs com técnicas clássicas baseadas em RNAs do tipo MLPs.

1.4 Organização da Monografia

O Capítulo 2 descreve o problema de previsão de vazões e faz uma revisão bibliográfica dos principais métodos e artigos para a previsão desta série de dados. Este capítulo também introduz a série de Energia Natural Afluente e mostra sua importância.

O Capítulo 3 traz a revisão bibliográfica da técnica de aprendizado empregada neste trabalho: *Support Vector Machines* e os conceitos que tornam esta técnica otimizada para a previsão e classificação de séries temporais.

No Capítulo 3 é mostrada a metodologia de previsão da série de Energia Natural Afluente, assim como sua desagregação para compor a série prevista individual de cada usina.

O Capítulo 4 discute e analisa os resultados obtidos assim como seus principais dados estatísticos e a eficiência da previsão da série agregada ENA quando comparada com a previsão tradicional de séries de vazões tanto utilizando SVM quanto RNA.

O Capítulo 5 fecha a monografia com as considerações finais obtidas no trabalho e metodologia proposto e sugere possíveis trabalhos futuros que possam explorar de forma mais abrangente a usabilidade da previsão de vazões afluentes utilizando a série ENA.

2

Descrição do Problema

Este capítulo apresenta, na Seção 2.1 as Considerações Iniciais do problema abordado e a importância do mesmo. Na Seção 2.2 é mostrada a previsão de vazão no setor elétrico, além de uma revisão da literatura e as principais técnicas de previsão de vazões. A Seção 2.3 introduz a série de Energia Natural Afluente e a sua relação com a série de vazões afluentes.

2.1 Considerações Iniciais

A geração de energia elétrica consolida-se como uma atividade de extrema importância para a economia em geral. Entre as formas de geração de energia as que utilizam fontes hidrominerais são as que possuem o maior potencial energético no Brasil representando a maior parte da energia consumida (Matriz de energia elétrica, 2011).

O estudo do comportamento da água e a criação de um modelo capaz de representá-lo de forma satisfatória são essenciais para o planejamento das usinas além de medir o impacto da construção de obras e tornar as usinas mais competitivas (de Braga *et al.*, 2011).

2.2 Previsão de Vazões no Setor Elétrico

Entre os vários fatores que possuem influência direta na geração de energia pelas hidrelétricas encontra-se a série de vazões, que mede a quantidade de água disponível em determinado período e sua queda. Embora essa série dependa das características geográficas específicas de cada reservatório, ela segue um comportamento sazonal com periodicidade anual, ou seja, a curva de vazão

apresenta um perfil histórico que segue um padrão anual (Figura 1). Esse padrão é observado através dos dados obtidos no ONS (Operador Nacional do Sistema Elétrico, 2011), que fornece relatórios anuais das vazões diárias e mensais das usinas em operação no Brasil desde 1931.

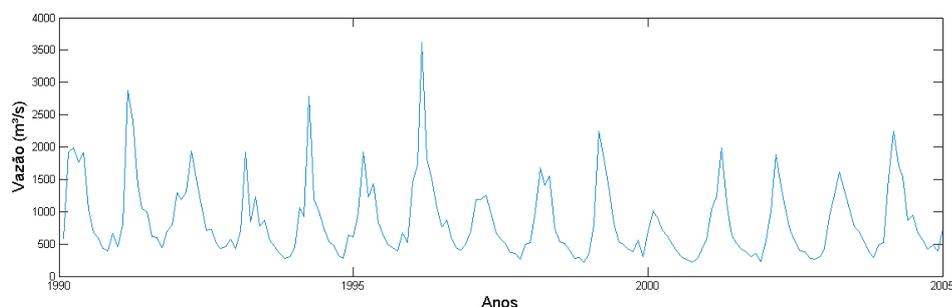


Figura 1 – Série Histórica de Vazões Afluentes da hidrelétrica de Furnas dos anos de 1990 até 2005.

A previsão de vazões é a estimativa do valor das vazões futuras para um determinado período de tempo. Além de sua importância para as usinas hidrelétricas, as previsões de afluências permitem a tomada de decisões em relação às cheias excepcionais, desde que feita com uma relativa precisão e antecedência (Guilhon, 2002).

O período de tempo no futuro que se deseja prever é chamado de horizonte de previsão. No setor elétrico os horizontes são divididos em três: curto, médio e longo prazo (Soares Filho, 1987). Previsões de curto prazo utilizam dados de vazões diárias e realizam a previsão para até 14 dias à frente, previsões de médio prazo analisam os dados de vazões semanais para prever até seis semanas à frente (Guilhon, 2002). Esse trabalho foca na previsão de Energia Natural Afluente e vazão de longo prazo, que utiliza os dados históricos mensais para previsão de normalmente até 12 meses à frente. Segundo Yeh *et al.* (1982) e Maurer e Lettenmaier (2004) em estudos focados em horizontes de longo prazo, demonstrou-se que quanto maior o horizonte de previsão maior os benefícios econômicos gerados pela previsão. Portanto, quanto maior a quantidade de meses à frente previstos com certa precisão, maior será os benefícios do previsor para as hidrelétricas.

A série de vazão é estocástica, não monotônica e não-linear, ou seja, tem origem em comportamentos aleatórios e não segue um único sentido. Devido a

essas características e à sua sazonalidade não é possível fazer uma estimação da série de forma satisfatória em modelos auto-regressivos médias móveis como o modelo ARMA(p,q) (Ehlers, 2005). Para lidar com essa limitação, em 1970, foi proposto uma modificação no modelo ARMA conhecido como SARIMA (Box e Jenkins, 1976). A previsão de vazões futuras nesse modelo é realizada através de uma variação da função de estimação e horizontes maiores de previsão podem ser atingidos de forma recursiva.

Modarres (2007) utiliza o modelo SARIMA para a previsão de vazões do tipo um passo a frente e do tipo 12 passos a frente. O estudo foi aplicado no Rio Zayandehrud, Irã, em três períodos de tempo diferentes: janeiro de 1990 até dezembro 1999 para a previsão doze passos a frente e os períodos de janeiro de 1997 até dezembro de 1999 e janeiro de 1999 até dezembro de 1999 para a previsão um passo a frente. Foram obtidos resultados expressivos para todos os períodos, tendo 15,82% de erro médio no primeiro período e 2,12% e 0,42% sucessivamente para os outros dois períodos.

Entretanto, embora o SARIMA e outras variações de modelos auto regressivos, possuam um resultado satisfatório para previsão de séries de vazões, o Brasil apresenta certas particularidades em relação à sua rede hidrográfica: fatores climáticos e chuvas diferem ao longo da área continental do país e a generalização e o ajuste dos estimadores auto-regressivos é uma tarefa complexa (Siqueira *et al.*, 1998). Uma alternativa para a previsão de vazões é a utilização de modelos do tipo caixa-preta, como por exemplo, os modelos baseados em Inteligência Computacional.

O modelo genérico de Redes Neurais Artificiais (RNA) é utilizado com grande recorrência na literatura tendo resultados positivos. Entre os trabalhos feitos na área é possível destacar os trabalhos de (Zealand *et al.*, 1999) que utiliza as RNA's para previsão de vazões semanais de horizonte de até quatro passos a frente, Dibike e Solomatine (2001) que realiza a previsão semanal de vazão utilizando os valores de *Runoff* e de precipitação para a composição do previsor, Jain e Kumar (2007) que propõe um modelo híbrido entre as RNA's e modelos auto-regressivos para a previsão de vazão mensal e de Braga *et al.* (2011) que utiliza as RNA's para a previsão de vazão em um horizonte mensal através de dois treinamentos distintos: contínuo e único obtendo resultados expressivos com

19,48% de erro MAPE para Furnas, utilizando treinamento contínuo e 20,79% de erro utilizando treinamento fixo.

As Redes *Neuro-Fuzzy*, assim como as Redes Neurais Artificiais são amplamente utilizadas na literatura. O trabalho proposto por Luna *et al.* (2007a) apresenta uma metodologia que realiza a previsão das vazões para a usina de Furnas seguindo um horizonte mensal utilizando um método baseado em regras *fuzzy* adaptativas, denominado A-FSM. Neste trabalho, os dados estão apresentados desde 1931 até 2005 seguindo uma discretização mensal, no qual representam o volume da vazão da Usina de Furnas. Para o ajuste do modelo de previsão foram utilizados os dados de 1931 até 1995 e os testes foram realizados para os anos de 1996 até 2005. Os resultados obtidos com o sistema A-FSM mostram um erro de 19,08%, o que é inferior aos erros obtidos por outros sistemas relacionados, tais como: C-FSM (Luna *et al.*, 2007b) que possui 20,19% e ANFIS (Jang, 1993) que apresenta 20,12%.

Além dos modelos heurísticos tradicionais para a previsão de vazão, outros vem se destacando na literatura como por exemplo o *Support Vector Machines* (SVM) (Vladimir e Vapnik, 1995; Gunn, 1998), que é o caso deste trabalho. Na literatura embora a técnica seja relativamente nova comparada às outras técnicas de aprendizado de máquina, existem vários trabalhos que utilizam a regressão do SVM para previsão de séries temporais e inclusive prever as séries de vazões.

Entre os trabalhos realizados está o proposto por (Li *et al.*, 2010) que divide a previsão em duas vertentes. Para a determinação dos parâmetros essenciais ao SVM é utilizada a técnica de Algoritmo Genético, depois os resultados são utilizados para previsão em uma forma modificada SVM. A metodologia proposta foi aplicada na Reserva de Shihmen no Taiwan, treinando o modelo com dados de 1974 à 1994 e realizando a previsão de doze passos a frente de 1994 à 2004. Embora tenha conseguido resultados expressivos, o autor destaca que em períodos chuvosos a metodologia proposta pode não ser adequada.

O trabalho proposto por Maity *et al.* (2010) utiliza o SVM para a previsão de vazões na estação de Basantpur na Índia, foram utilizados dados de 1972 à 1995 para o treinamento e a previsão foi realizada de 1995 à 2004. Para determinação de parâmetros foi feita uma calibração dos mesmos durante o período de ajuste do

modelo. Os erros encontrados foram inferiores aos erros obtidos por modelos tradicionais como os modelos propostos de Box-Jekings (Hoff, 1983).

Wang *et al.* (2010) propõe um sistema híbrido entre o método de enxame de partículas (Kennedy e Eberhart, 1995) e o modelo SVM. Na metodologia apresentada o trabalho realiza a busca de parâmetros através do enxame de partículas e então aplica os parâmetros encontrados no modelo SVM para previsão. A aplicação da técnica foi realizada na reserva de Fengtan na China e apresentou resultados efetivos ao ser comparado com as Redes Neurais Artificiais.

2.3 Energia Natural Afluente

A série de Energia Natural Afluente de um determinado subsistema é gerada a partir das séries de vazões afluente de cada usina do subsistema multiplicado pela sua produtividade, considerando que a usina está com 65% do seu reservatório (Operador Nacional do Sistema Elétrico, 2011):

$$ENA_{SUBSISTEMA} = \sum_{j=1}^m (Q_{nat}(j, t) \cdot p(j)) \quad (1)$$

onde,

t = intervalo de tempo de cálculo da ENA;

Q_{nat} = vazão natural do aproveitamento no intervalo de tempo considerado;

p = produtibilidade média do conjunto turbina-gerador do aproveitamento hidrelétrico, referente à queda obtida pela diferença entre o nível de montante, correspondente a um armazenamento de 65% do volume útil, e o nível médio do canal de fuga;

j = aproveitamento pertencente ao sistema de aproveitamentos do subsistema considerado;

m = número de aproveitamentos existentes no sistema de aproveitamentos do subsistema considerado.

Essa série é essencial ao setor elétrico por apresentar a quantidade de produção de potência elétrica que um subsistema de hidrelétricas gerou em um determinado período de tempo.

Um possível subsistema é o das usinas de Furnas e Peixoto. Furnas é uma usina de cabeceira enquanto Peixoto é uma de suas afluentes, o que as tornam linearmente dependentes. Para se calcular a série ENA desse subsistema é necessário multiplicar, a vazão de cada uma (m^3/s) pela sua respectiva produtividade à 65% ($\text{MW}/(\text{m}^3/\text{s})$) e somar as duas séries (Figura 2).

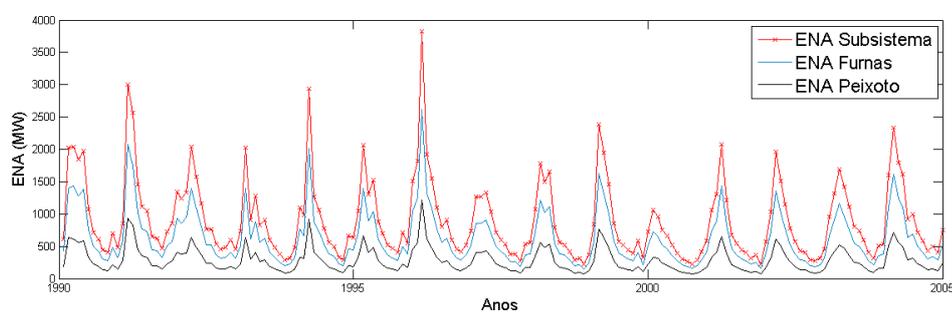


Figura 2 - Série ENA para o subsistema Furnas e Peixoto no período de 1990 até 2005.

3

A Técnica *Support Vector Machines*

Este capítulo apresenta, na Seção 3.1 o conceito do aprendizado supervisionado e como ele se aplica à técnica de Support Vector Machines. A Seção 3.2 mostra o histórico do SVM e sua utilização, logo em seguida são apresentados alguns dos seus conceitos: na Seção 3.3 está descrita a Dimensão VC, que é usada como parâmetro para a minimização do risco estrutural (3.4) e a na Seção 3.6 é apresentado as funções Kernel e como elas otimizam a solução SVM. Finalmente nas Seções 3.5 e 3.7 são abordados o SVC e o SVR, que fazem a classificação e a regressão nas máquinas de vetores suporte.

3.1 Aprendizado Supervisionado

O Aprendizado de Máquina (AM) é um conjunto de técnicas computacionais que tem por objetivo a criação de sistemas capazes de adquirir e organizar o conhecimento de forma automática (Mitchell, 1997).

Uma das técnicas do AM é o Aprendizado Supervisionado que consiste em criar uma função através de um conjunto de treinamento (Mitchell, 1997). Esse conjunto possui pares de objetos de entrada (tipicamente vetores) e saídas desejadas, que pode ser um número real (para casos de regressão) ou um rótulo de uma classe (para casos de classificação).

O objetivo do Aprendizado Supervisionado é utilizar a função criada para prever o valor de saída (resultado) através dos dados de entrada (Figura 3). Os algoritmos principais dessa técnica são: Redes Neurais, algoritmo *Nearest Neighbor* (NN), árvores de decisão e a máquina de vetores de suporte (*Support Vector Machines* - SVM), entre outros.

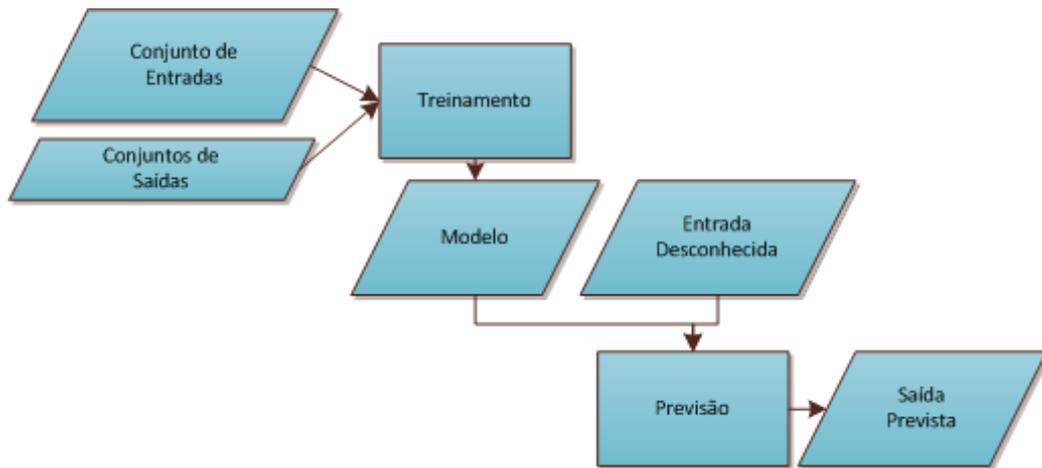


Figura 3 - Fluxograma de aprendizado e previsão dos algoritmos do tipo Aprendizado Supervisionado.

3.2 A Técnica

O SVM pode ser entendido como um conjunto de técnicas utilizadas tanto pra classificação (*Support Vector Classification - SVC*) quanto para regressão (*Support Vector Regression - SVR*). Utiliza-se da minimização estrutural de risco (*Structural Risk Minimization - SRM*), um conceito considerado superior ao de minimização do risco empírico (*Empirical Risk Minimization - ERM*) que é utilizado pelas Redes Neurais mais convencionais (Gunn et al., 1997). O uso do conceito SRM possibilita que a SVM tenha uma melhor generalização e por consequência tenha um bom desempenho na aprendizagem estatística.

Para a construção do conhecimento a técnica de aprendizado SVM utiliza como conceito chave a minimização do risco estrutural, que é baseada na dimensão de Vapnik-Chervonenkis. É importante visar que a técnica SVM é dividida em duas vertentes, pois embora tenha sido criada para atender casos em que as saídas são números discretos (SVC), ela foi modificada para também atender casos em que as saídas são números contínuos (SVR).

Um ponto que torna essa técnica de aprendizado extremamente atrativa é a extensa fundamentação teórica existente, o que não acontece nas Redes Neurais, por exemplo. Essa fundamentação permite o estudo aprofundado da técnica.

Entre suas características principais destacam-se a alta capacidade de generalização e a robustez da máquina de vetores suporte quando confrontada com dados de grande dimensão, uma vez que não tende a ficar super (*overfitting*) ou sub ajustada (*underfitting*), ao contrário de outras técnicas de aprendizado (Lorena *et al.*, 2007).

Embora possua muitas características positivas, o SVM possui algumas limitações que prejudicam a sua usabilidade, como:

- Velocidade de treinamento menor em relação a outras técnicas, como Redes Neurais;
- Alta complexidade computacional, o que pode ser agravado quando existe um grande conjunto de dados para treinamento;
- Sensibilidade e dificuldade para escolha de parâmetros;
- Dificuldade de interpretação do conhecimento adquirido.

Entretanto, diversos estudos foram feitos para diminuir essas limitações, o que somado com a alta capacidade de generalização e a sua robustez faz do SVM uma das técnicas de aprendizado mais exploradas e estudadas atualmente.

3.3 Dimensão de Vapnik-Chervonenkis (VC)

A dimensão Vapnik-Chervonenkis ou dimensão VC é uma medida da capacidade de classificação de um grupo de funções indicadoras calculadas previamente por uma máquina de aprendizagem. O seu valor é equivalente ao número máximo de exemplos de treinamento que podem ser aprendidos sem erros.

O valor da dimensão VC é $n + 1$ sendo n a dimensão do espaço vetorial em questão. Por exemplo, $VC = 2$ quando o problema pode ser separado por uma reta, $VC = 3$ quando o problema pode ser separado por um plano e assim por diante. Um exemplo do valor da dimensão é visto na Figura 4. Nesse exemplo o valor da dimensão VC é 2, uma vez que o problema pode ser separado por uma reta.

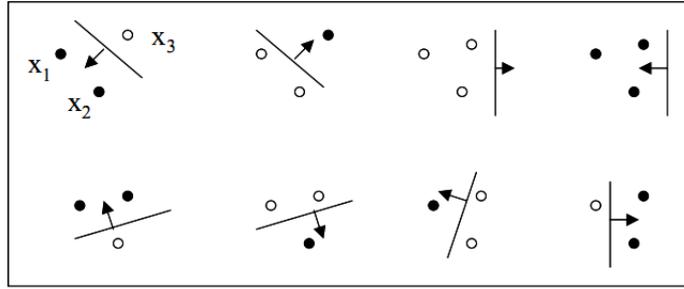


Figura 4 - Dimensão VC. Fonte: Semolini, 2002.

A dimensão de VC é utilizada como parâmetro de controle para ajustar um princípio indutivo conhecido como minimização do risco estrutural (Vapnik (1963); Vapnik e Chervonenkis (1964)). Porém, calcular a dimensão VC não é uma tarefa trivial, podendo o valor ser desconhecido ou infinito (Lorena *et al.*, 2007).

3.4 Minimização do Risco Estrutural (SRM)

Para obter um melhor desempenho nas previsões é esperado que a função de classificação f consiga chegar ao menor erro possível durante o treinamento. É importante notar que o erro nesse caso é o número de previsões incorretas de f , dessa forma o risco empírico é a medida de perda entre a resposta desejada e a resposta obtida (real). A definição matemática do risco empírico é mostrada na Equação 2, onde $c(f(x_i), y_i)$ é a função de custo da previsão $f(x_i)$ tendo y_i como saída desejada e n o número de elementos do conjunto de treinamento (Lorena *et al.*, 2007).

$$R_{emp}(f) = \frac{1}{n} \sum_{i=1}^n c(f(x_i), y_i) \quad (2)$$

Através da dimensão VC foi desenvolvida uma expressão que indica o limite superior do risco funcional tendo probabilidade $1 - e$ de ocorrer, sendo e um valor entre 0 e 1 (Vapnik, 1998). Essa expressão pode ser visualizada na Equação 3.

$$R_{funcional}(f) \leq R_{empirico} + R_{estrutural}(h, N, e) \quad (3)$$

A formulação do risco estrutural pode ser visualizada na Equação 4, Sendo h a dimensão VC da classe de funções F na qual f pertence, N o número de amostras de treinamento e e o parâmetro escolhido.

$$R_{\text{estrutural}}(h, N, e) = \sqrt{\frac{h \left(\ln \left(\frac{2N}{h} \right) + 1 \right) - \ln \left(\frac{e}{4} \right)}{N}} \quad (4)$$

O ideal é encontrar um valor que equilibre o risco empírico com o risco estrutural, uma vez que a diminuição do primeiro implica no crescimento do segundo. Ou seja, deve-se obter o menor limite possível para o risco funcional.

Um grande problema da minimização do risco estrutural está ligado à complexidade para encontrar o valor exato da dimensão VC (h na fórmula), então o valor costuma ser estimado por meio de limites superiores (Vapnik *et al.*, 1994). A formulação que mostra essa estimação pode ser vista na Equação 5.

$$h \leq 1 + \min \left(N, \left(\frac{r^2}{T^2} \right) \right) \quad (5)$$

Sendo T a margem de separação entre as classes e r o menor raio possível de uma hiper-esfera circunscrita aos vetores de treinamento. Outra maneira de minimizar o risco estrutural é a maximização da margem de separação T , uma vez que T é inversamente proporcional à dimensão VC.

3.5 Support Vector Classification (SVC)

Ao realizar a classificação o SVC utiliza o conceito de margem. Para entendê-lo deve-se considerar um hiperplano $f(x) = (w \cdot x) + b$. A margem é a menor distância entre os exemplos do conjunto de treinamento e o hiperplano utilizado para a separação dessas classes (Lorena *et al.*, 2007). Ou seja, a margem determina quão bem duas classes podem ser separadas (Smola *et al.*, 2000).

De maneira mais formal, o SVC procura maximizar a margem utilizando um hiperplano ótimo, ou seja, o hiperplano de separação que possui a maior margem considerando um conjunto de treinamento linearmente separável, o que pode ser obtido através da Equação 6, considerando como restrição $y_i(w \cdot x_i + b) - 1 \geq 0, \forall i = 1, \dots, n$ (Lorena *et al.*, 2007). Ao minimizar essa equação implementa-se

o princípio de minimização do risco estrutural (SRM – Seção 3.1.2), que supõe a seguinte desigualdade $\|w\| < A$, sendo A um escalar dos números reais (Rodrigues, 2007).

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (6)$$

Outro conceito importante para o SVC é o de vetores suporte. Esses vetores são padrões críticos que sozinhos determinam o hiperplano ótimo, enquanto os outros padrões (não-críticos) são considerados irrelevantes (Smola *et al.*, 2000). Na Figura 5 está um exemplo de margem e vetores de suporte (são destacados por círculos externos aos padrões).

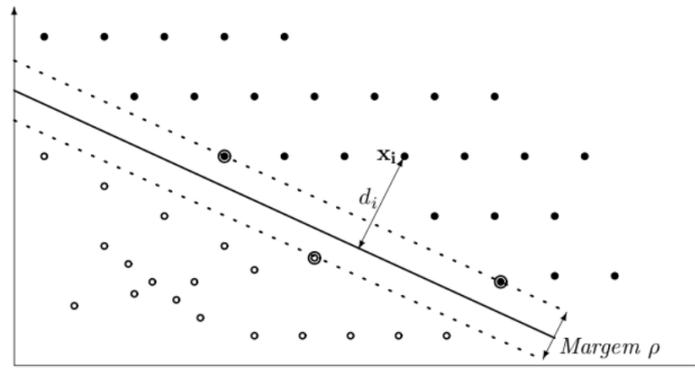


Figura 5 – Margem ρ e os vetores de suporte. Fonte: Lima, 2002.

A predição de uma amostra para classificação binária é realizada pela fórmula da Equação 7, em que n é o a quantidade de elementos do conjunto de treinamento e α , assim como b são parâmetros criados pelo SVM para a construção de uma solução otimizada (Parrela, 2007). Para a classificação multiclasse pode-se recorrer a duas soluções: decomposição do problema para vários subproblemas binários ou a modificação do algoritmo do SVM. Como o segundo método geralmente é custoso computacionalmente, o método mais comumente usado é o de decomposição (Lorena *et al.*, 2007).

$$f(x) = \text{sign} \left(\sum_{i=1}^n y_i \alpha_i (x \cdot x_i) + b \right) \quad (7)$$

Quando o problema não é linearmente separável é introduzido o conceito de erro para que o método da separação de hiperplanos possa ser generalizado. Isso é feito através das variáveis de folga ξ_i , para todo $i = 1, \dots, n$, que tornam a solução mais flexível considerando o hiperplano como $y^i [(w, x^i) + b] \geq 1 - \xi_i$,

sendo $\xi_i \geq 0$. Portanto o hiperplano que maximiza a margem separadora pode ser obtido pela minimização da Equação 8, chamada de margem suave. Segundo Cortes (1995), o parâmetro C de regulação deve ser escolhido na maioria dos casos empiricamente e deve refletir a existência de ruído nos dados.

$$\Phi(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i \quad (8)$$

Esse procedimento é dado pelo teorema de Cover, que diz que dado um conjunto de dados não linear no espaço X , esse espaço pode ser transformado no espaço de características \mathfrak{S} que possui uma alta probabilidade de ter os dados linearmente separáveis (Lorena *et al.*, 2007).

Como \mathfrak{S} pode ter dimensão muito grande e até mesmo infinita, a computação de Φ pode se tornar inviável. Portanto é necessário modificar a fórmula de previsão, através das chamadas funções *Kernel*. Essas funções substituem o $(x \cdot x_i)$ da Equação 7 para permitir o crescimento da solução SVC gerando uma melhor classificação.

3.6 Funções Kernel

Uma função *Kernel* é uma função que recebe como parâmetros x_i e x_j do espaço de entradas e calcula o produto escalar desses parâmetros no espaço de características (Equação 9). Sendo que a função $\Phi(\cdot)$ deve pertencer a um domínio onde seja possível o calculo do produto interno.

$$K(x_i, x_j) = \langle \Phi(x_i) \cdot \Phi(x_j) \rangle \quad (9)$$

Os tipos mais comuns de *Kernels* podem ser vistos na Tabela 1, sendo que em alguns deles é necessário a configuração de parâmetros adicionais.

Tabela 1 – Tipos mais comuns de Kernels. Fonte: Lorena et al., 2007.

Tipo de Kernel	Função $K(x_i, x_j)$	Índice B
Polinomial	$(\delta(x_i \cdot x_j) + \kappa)^d$	δ, κ e d
Gaussiano	$\exp(-\sigma \ x_i - x_j\ ^2)$	σ
Sigmoidal	$\tanh(\delta(x_i \cdot x_j) + \kappa)$	δ e κ

3.7 Support Vector Regression (SVR)

A diferença da regressão com a classificação está no fato da primeira apresentar muitos e possivelmente com parâmetros de saída tendendo ao infinito. Ou seja, $y_i \in R$ ao invés de ser parte de um número finito de categorias. Isso torna a regressão uma generalização da classificação, em que a resposta varia continuamente dentro de uma faixa esperada.

A regressão em SVM é semelhante à classificação, mas utiliza-se uma função de perda. Essa função pode ser alterada dependendo do problema, mas a mais comum é a ϵ -insensitiva criada por Vapnik (Figura 6).

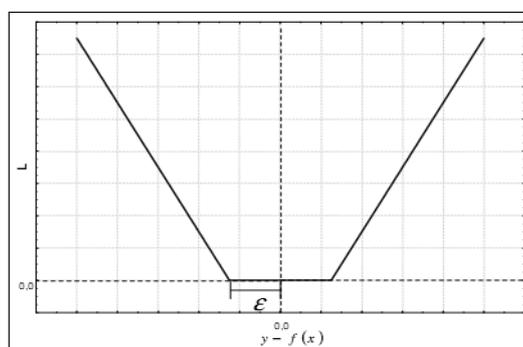


Figura 6 – Função de Perda ϵ -insensitiva. Fonte: Ferro, 2007.

A Figura 6 mostra como o erro ϵ funciona. Quanto maior o erro, maior é a penalização L e se não houver erro não há penalização. Isso forma uma região de tolerância determinada por $(-\epsilon, +\epsilon)$ que é a chamada de região insensitiva. Entretanto, quando o erro não está dentro dessa região é aplicada a penalização em proporção linear ao seu módulo (Ferro, 2007). Ou seja, o erro não é levado em

consideração se ele for menor que ε , porém não será aceito nenhum erro maior que esse parâmetro (Smola, 2002).

O conceito de margem, assim como na classificação, também é empregado. A margem no SVR é uma região em torno de uma curva ajustada a partir dos erros que cujos módulos extrapolam ε . Essa região mostra a região de confiança (Figura 7).

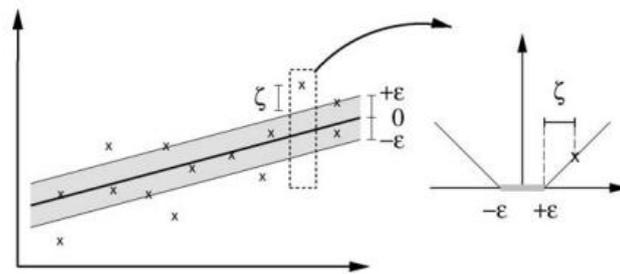


Figura 7 – Conceito de Margem no SVR. Fonte: Smola, 2002.

As previsões são feitas de forma semelhante ao SVC levando em consideração o erro para obter números contínuos como resultados, e assim como no problema da classificação são utilizadas as funções *Kernel* quando o problema não pode ser representado de forma linear.

4

Metodologia Proposta

Este capítulo apresenta, na Seção 4.1 as Considerações Iniciais, na Seção 4.2 é comentado sobre a identificação e ajuste dos parâmetros da biblioteca, na Seção 4.3 é apresentado o conjunto de treinamento e o tratamento de dados e nas Seções 4.4 e 4.5 são propostas as metodologias de previsão.

4.1 Considerações Iniciais

Este trabalho foi desenvolvido utilizando a biblioteca *LibSVM* (Chang e Lin, 2011) que implementa computacionalmente os métodos das *Support Vector Machines* após a configuração de parâmetros. Essa biblioteca é consolidada na literatura por estabelecer uma função de rápida convergência (Fan *et al.*, 2005) alta portabilidade e atualizações frequentes.

4.2 Identificação e Ajuste

Para a configuração do SVM foi feita uma busca exaustiva de parâmetros com o objetivo de se encontrar os mais bem adaptados ao modelo de previsão tanto da série de Energia Natural Afluyente quanto da série de Vazões em um determinado período de tempo. O critério adotado para escolher os melhores parâmetros é baseado no modelo que possua o menor erro quadrático médio (MAPE):

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{X_i - \tilde{X}_i}{X_i} \right| \quad (10)$$

onde X_i é o valor real e \tilde{X}_i o valor previsto. Os valores de configuração da biblioteca variam de acordo com a Tabela 2 e foram escolhidos de forma aleatória devido ao grande número de possibilidades e de intervalos de configurações.

Tabela 2 - Parâmetros utilizados na busca exaustiva do SVM

Parâmetro	Varição
Função de Erro	$[\varepsilon - SVR, \nu - SVR]$
Grau no Kernel Polinomial	[0.01]
Parâmetro C (custo)	[0.01 – 500]
Parâmetro ε (ε -SVR)	[1 – 100]
Parâmetro ν (ν -SVR)	[0 – 1]
Tipo de Kernel	[Linear, Radial Basis Function, Sigmoid]

A metodologia adotada para a busca exaustiva separou o conjunto de dados em três, sendo eles respectivamente: treino, validação e teste (Figura 8).

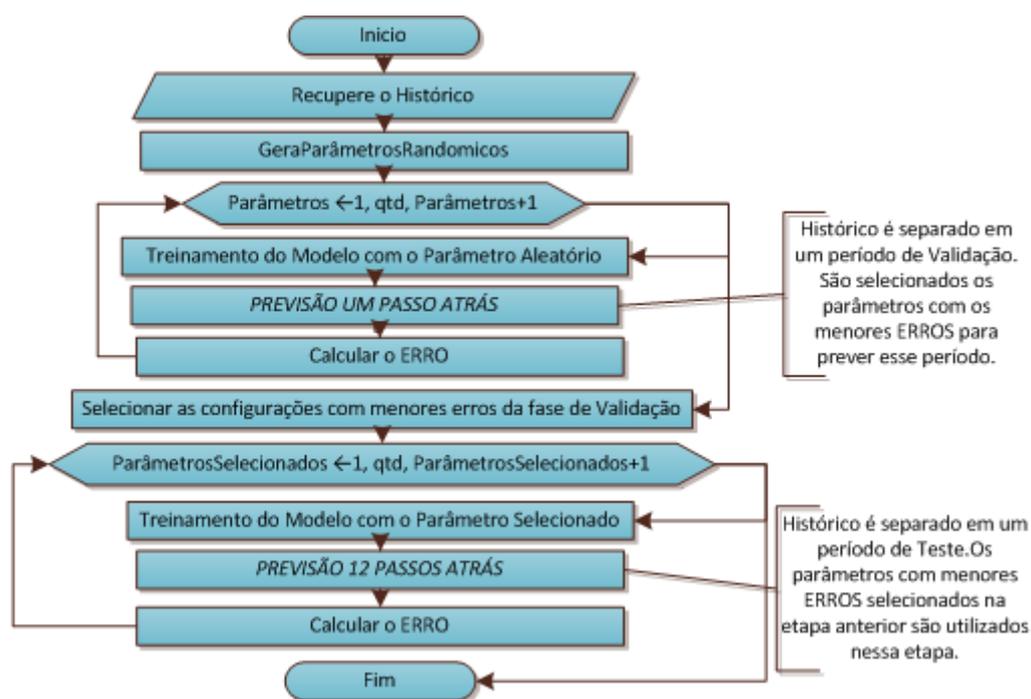


Figura 8 - Fluxograma de busca exaustiva.

As fases são executadas de forma sequencial: na primeira é ajustado e configurado o modelo de previsão, na segunda o modelo é utilizado para prever uma amostra desconhecida ao previsor e, na última fase, os modelos que apresentarem os menores erros são utilizados para prever o período de validação para horizontes

maiores de previsão. A separação do histórico é necessária para não criar um previsor super ajustado (*overfitting*) ao problema.

4.3 Conjunto de treinamento e tratamento de dados

O conjunto de treinamento para o *Support Vector Regression* (SVR) utilizado corresponde a série ENA calculada de um subsistema de usinas. Ela foi dividida em um período de treinamento para a criação do modelo e um período de previsão para a efetivação do modelo criado.

O processo de desagregação da série de ENA após a previsão foi feita de forma inversa ao cálculo da série (Seção 2.3), sendo utilizada a porcentagem média da vazão de cada usina em relação à série ENA no período de treino através da seguinte equação:

$$\text{Porcentagem ENA} = \frac{1}{(n-t)} \sum_t^n (V_i \div ENA_i) \times 100 \quad (11)$$

onde,

t = período inicial da fase de treinamento;

n = período final da fase de treinamento;

V_i = vazão natural da usina a ser considerada no período i ;

ENA_i = energia natural afluyente do subsistema no período i ;

Após o cálculo da porcentagem média de cada usina é feita a multiplicação dos valores obtidos na previsão da ENA pela porcentagem e a divisão do valor pela produtividade média da usina a 65% do armazenamento. Dessa forma a série prevista da ENA é separada e específica para cada usina que a compõe. O processo de cálculo e desagregação da série da ENA é feita como mostrado na Figura 9.

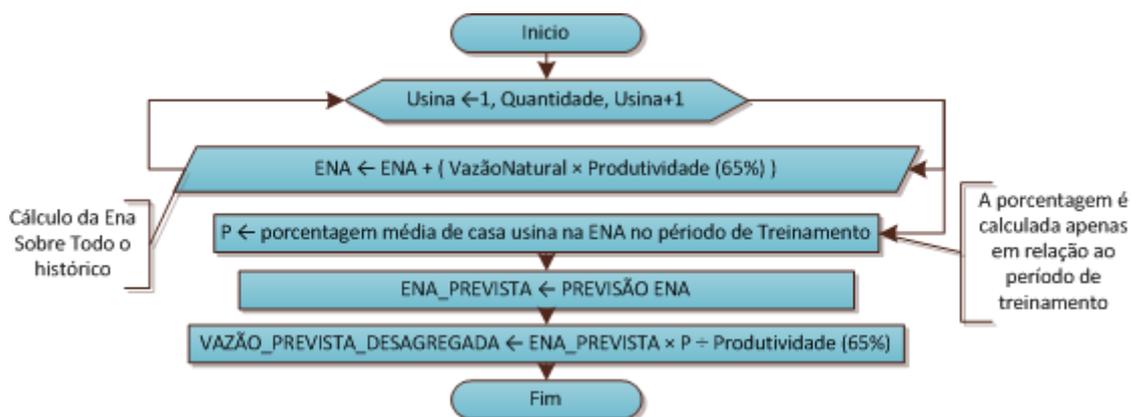


Figura 9 - Fluxograma de cálculo e desagregação da série de ENA.

Tanto a série de ENA quanto a série de Vazões Naturais foram treinadas utilizando um *delay* ou *lag* de valor igual a 1. Ou seja, referente ao dado do mês anterior ao mês a ser previsto. O valor da vazão do mês imediatamente anterior pode ser conhecido (Previsão Um Passo Atrás) ou ser estimado (Previsão Até Doze Passos Atrás).

Para preservar as características e singularidades entre os meses eles são treinados individualmente, criando um modelo de treinamento específico para cada um. Ou seja, para fazer o treinamento do mês x o conjunto de treinamento terá como entrada o mês $x - 1$, enquanto a saída será a vazão correspondente do mês x nesse período (Tabela 3).

Tabela 3 - Conjunto de Treinamento (mês x - delay 1)

Entrada	Saída
$mês_{x_1-1}$	$mês_{x_1}$
$mês_{x_2-1}$	$mês_{x_2}$
⋮	⋮
⋮	⋮
$mês_{x_n-1}$	$mês_{x_n}$

Para a correta utilização da biblioteca e a otimização dos resultados os dados de vazões foram padronizados linearmente através da seguinte equação:

$$x'_{ij} = \frac{x_{ij}}{\max x_{ij}} \quad (12)$$

onde x é o mês a ser transformado e o valor máximo se refere ao maior valor de todo o histórico.

4.4 Previsão Um Passo Atrás

A previsão Um Passo Atrás considera que é conhecido o mês anterior real ao mês que se deseja prever e ela é utilizada como fase de **VALIDAÇÃO** para as previsões com horizontes maiores (Figura 10).



Figura 10 - Fluxograma de Previsão Um Passo Atrás.

Ou seja, após o treinamento do modelo com o período de **TREINAMENTO** é feita a busca exaustiva de parâmetros (Seção 4.2) sobre a previsão Um Passo Atrás e armazenado os melhores componentes. A previsão Um Passo Atrás considera que é conhecido o mês anterior real ao mês que se deseja prever e ela é utilizada como fase de **VALIDAÇÃO** para as previsões com horizontes maiores.

4.5 Previsão Até Doze Passos Atrás

Além da Previsão Um Passo à Frente, este estudo aborda outra metodologia de previsão: a Previsão Até Doze Passos Atrás que é empregada como a fase de **TESTE**. A diferença entre as duas previsões está nos dados de entrada, enquanto a primeira previsão considera apenas os dados históricos reais a segunda considera o

valor previsto anteriormente, com isso ela propaga os valores da previsão até chegar em 12 meses atrás (Figura 11).

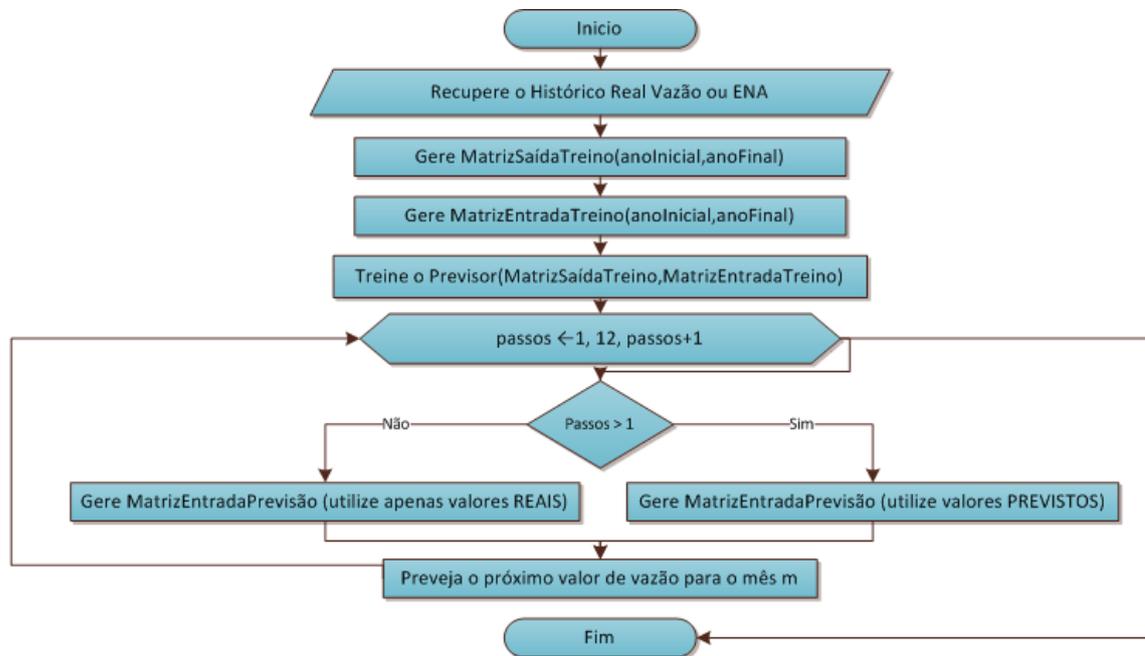


Figura 11 - Fluxograma de Previsão Até Doze Passos Atrás.

Essa previsão é feita após a busca exaustiva de parâmetros sobre a Previsão Um Passo à Frente e utiliza os melhores componentes selecionados por ela. O objetivo dessa previsão é mostrar adaptabilidade do previsor quando confrontado com um horizonte maior de previsão.

5

Resultados

Este capítulo apresenta na Seção 5.1 a instância de teste utilizada para a aplicação da metodologia, na Seção 5.2 são discutidos os resultados de previsão obtidos, na Seção 5.3 é feito um estudo com as principais variáveis estatísticas sob a série prevista e na Seção 5.4 o desempenho da previsão e desagregação da ENA é comparado com a previsão de vazão afluente individual.

5.1 Instância de Teste e Análise dos Dados

Os dados utilizados neste trabalho foram fornecidos pela ONS (Operador Nacional do Sistema Elétrico, 2011) e se referem à produtividade média do conjunto turbina-gerador do aproveitamento hidrelétrica correspondente a um armazenamento de 65% do volume útil e à série de vazões afluentes mensais.

Foi utilizado um subsistema de quatro usinas referentes a Bacia do Rio Grande, sendo elas: Furnas, Mascarenhas de Moraes (Peixoto), Marimbondo e Água Vermelha. A escolha das usinas se deve ao fato delas estarem distribuídas em toda a extensão da bacia e terem ligação direta na vazão uma da outra como pode ser observado pela Figura 12.

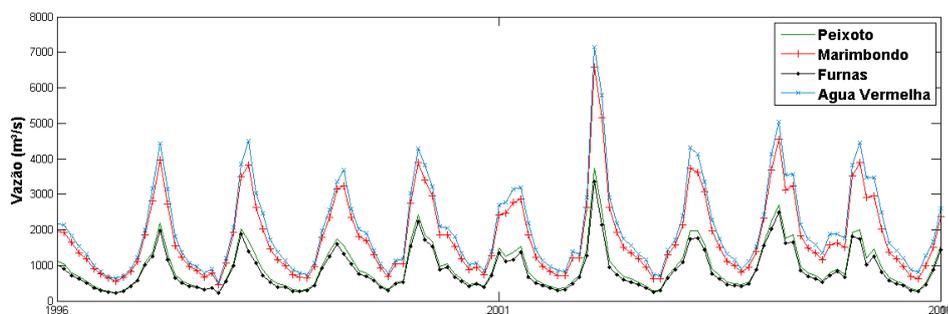


Figura 12 - Dados Brutos dos anos de 1996 a 2010 de Vazão para as usinas de Furnas, Mascarenhas de Moraes (Peixoto), Marimbondo e Água Vermelha

A bacia em questão está localizada entre os estados de Minas Geras e São Paulo, tem aproximadamente 145.000 km² de área de drenagem e possui uma série de reservatórios construídos para fins de geração de energia elétrica. A cascata de reservatórios no Rio Grande compreende as usinas de Camargos, Itutinga, Furnas, Mascarenhas de Moraes (Peixoto), L. C. B de Carvalho, Jaguará, Volta Grande, Porto Colômbia, Marimbondo e Água Vermelha, de montante para jusante (Atlas de Energia Elétrica do Brasil, ANEEL, 2011) (Figura 13).



Figura 13 - Diagrama Esquemático da Bacia do Rio Grande (Operador Nacional do Sistema, 2011)

Para a formação da série de Energia Natural Afluente foram recuperados os valores da produtividade de cada usina (Tabela 4). Esses valores foram utilizados em todos os cálculos e na instância de teste proposta nesse trabalho.

Tabela 4 - Produtividade à 65% de cada usina da instância de teste

Usina	Produtividade 65% Volume (MW/(m ³ /s))
Furnas	0,723
Mascarenhas de Moraes (Peixoto)	0,298
Marimbondo	0,44
Água Vermelha	0,442

Após a recuperação dos valores de produtividade de cada usina e das suas relativas séries de vazões afluentes históricas foi gerada a série de Energia Natural Afluente (ENA) desse subsistema (Figura 14).

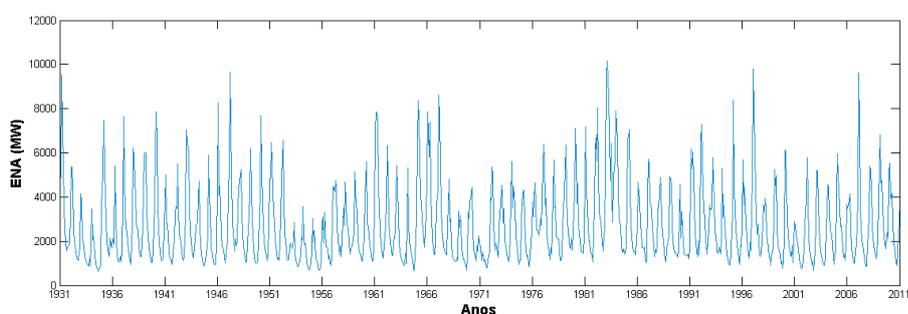


Figura 14 - Série de ENA calculada para o subsistema proposto.

A Tabela 5 mostra as principais variáveis estatísticas relacionando a série agregada ENA com as séries de vazões afluentes mensais de cada usina.

Tabela 5 - Principais variáveis estatísticas para a ENA e vazões do subsistema.

Variável	Furnas (m ³ /s)	Peixoto (m ³ /s)	Marimbondo (m ³ /s)	Água Vermelha (m ³ /s)	ENA (MW)
<i>Média</i>	954,7	1050,2	2006,2	2245,9	2725
<i>Mediana</i>	715	791	1569	1802	2104
<i>Máximo</i>	3621	4064	7228	7938	10153
<i>Mínimo</i>	210	225	465	530	614,17
<i>Desvio Padrão</i>	650,6s	718,3	1241,9	1339,1	1726,9
<i>Curtose</i>	5,1280	5,177	4,76521	4,572099	4,80197
<i>Assimetria</i>	1,4798	1,4795	1,35922	1,303692	1,3886
<i>Coefficiente Variação</i>	0,6823	0,6839	0,61846	0,596519	0,63372

Ao realizar a análise nos dados é possível observar que o coeficiente de variação apresenta alta variabilidade nos dados o que dificulta a previsão com uma grande taxa de acertos. A curtose em todas as séries analisadas é > 3 , o que indica que as séries são curvas leptocúrticas, ou seja, tem uma probabilidade de encontrar-se valores que se afastam da média. A assimetria analisada em todas as séries foi >1 e considerada positiva e à direita, o que também mostra a complexidade em padronizar os valores das séries.

5.2 Resultados Obtidos

A previsão da série de Energia Natural Afluente foi dividida em fase de treino, validação e teste. Essas fases foram escolhidas de forma a mostrar a evolução do erro da série de ENA com o aumento do horizonte de previsão. Para a comparação da eficiência da técnica *Support Vector Machines* a série foi submetida à mesma metodologia utilizando a técnica de Redes Neurais Artificiais. Para otimizar os resultados a RNA foi treinada utilizando *delay* igual a 5, por efetuar uma melhor generalização com esta quantidade de padrões de entrada na instancia de teste proposta.

A Previsão Um Passo Atrás (fase de **VALIDAÇÃO**) foi realizada através de uma busca exaustiva em duas mil configurações de parâmetros de entrada geradas automaticamente. O treinamento da série contou com dados de 1931 até 1979 e a previsão foi feita no período de 1980 até 2010. O gráfico comparativo entre a série prevista e a série real do melhor resultado, tanto da técnica *Support Vector Machines* quanto das Redes Neurais Artificiais pode ser vista na Figura 15.

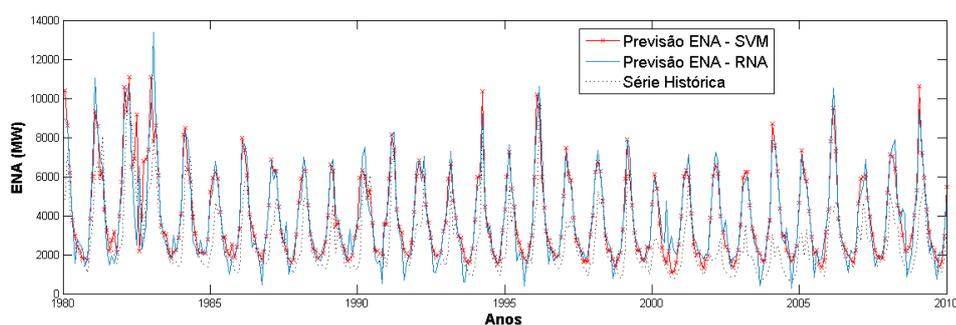


Figura 15 - Série da ENA Histórica comparada com a Previsão Um Passo Atrás feitas pelas técnicas SVM e RNA

Após a fase de validação foi realizada a fase de teste com horizontes de previsão de 2 até 12 meses. Essa fase utiliza as melhores configurações de parâmetros encontradas na fase anterior para a previsão de cada mês. Os períodos de treinamento e previsão foram feitos de forma similar à Previsão Um Passo Atrás, sendo o treinamento de 1931 até 1979 e a previsão de 1980 até 2010. Os erros MAPE encontrados na Previsão Um Passo Atrás e no final dos 12 passos da Previsão Até Doze Passos Atrás podem ser verificados na Tabela 6.

Tabela 6 - Erro MAPE em porcentagem das Previsões Um Passo Atrás e Doze Passos Atrás da instância de ENA proposta.

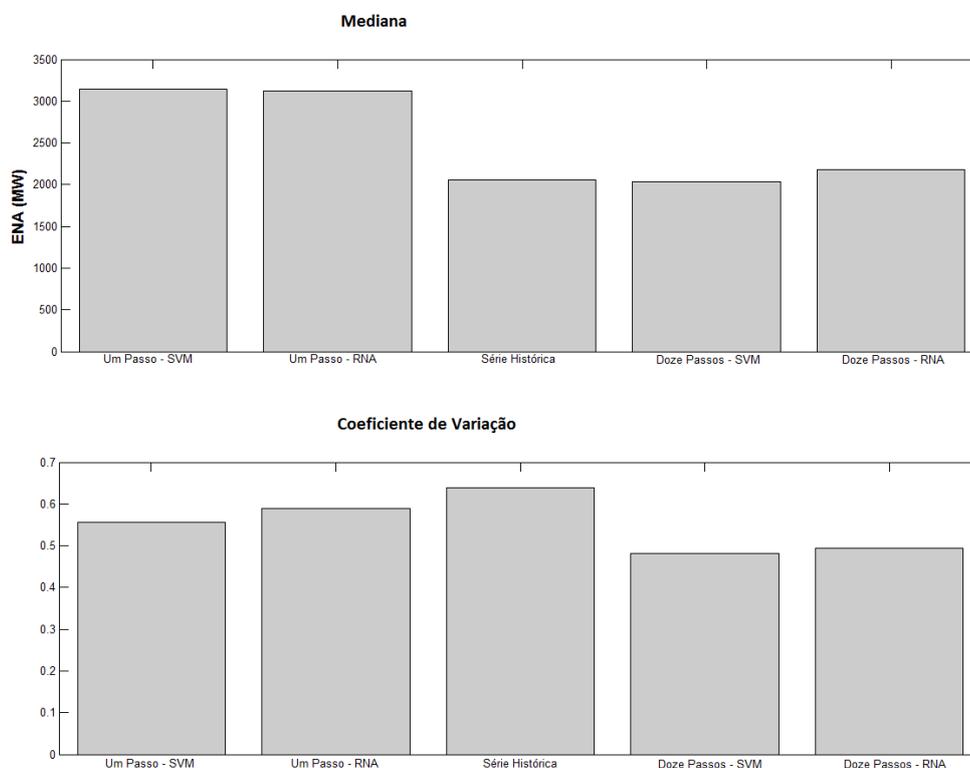
MAPE/ MÊS	PREVISÃO UM PASSO ATRÁS		PREVISÃO DOZE PASSOS ATRÁS	
	SVM	RNA	SVM	RNA
Janeiro	23,03%	27,53%	27,64%	30,18%
Fevereiro	24,40%	25,20%	26,70%	28,70%
Março	16,62%	20,98%	18,24%	20,21%
Abril	17,20%	14,70%	20,28%	23,51%
Maio	8,38%	10,73%	18,97%	18,02%
Junho	9,59%	12,11%	18,80%	19,58%
Julho	6,18%	5,60%	15,82%	16,51%
Agosto	8,22%	10,41%	16,43%	16,28%
Setembro	17,00%	20,18%	23,00%	25,12%
Outubro	24,40%	26,27%	29,26%	29,56%
Novembro	23,08%	26,00%	23,43%	28,96%
Dezembro	26,05%	18,76%	17,52%	27,36%

Ao observar a Tabela 6 é possível averiguar que o predictor SVM teve uma taxa de acerto maior quando comparado à previsão utilizando as Redes Neurais tanto para previsões de um passo quanto para a previsão de doze passos atrás. Os erros em ambos os predictors tendem a aumentar de acordo com o aumento da quantidade de passos, porém a diferença de porcentagem de erros entre um predictor e outro não é drástica e na maioria dos casos varia entre 2 e 3%.

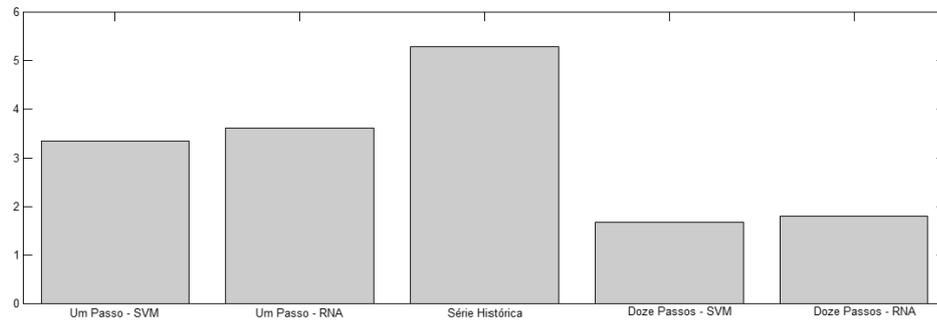
5.3 Comparação estatística entre as séries

Para uma previsão mais eficiente é importante que a série prevista reproduza alguns parâmetros estatísticos em relação à série história. Desta forma foi calculada a curtose, o desvio-padrão, a média e a assimetria da série de Energia Natural Afluyente período de previsão (1980-2010).

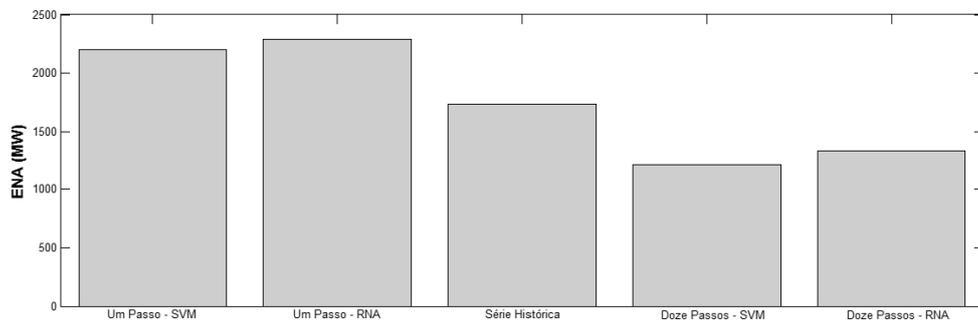
Foram comparados os resultados da série na Previsão Um Passo Atrás e no horizonte de 12 meses da Previsão Até Doze Passos Atrás tanto para técnica de *Support Vector Machines* quanto para a técnica de Redes Neurais (Figura 16).



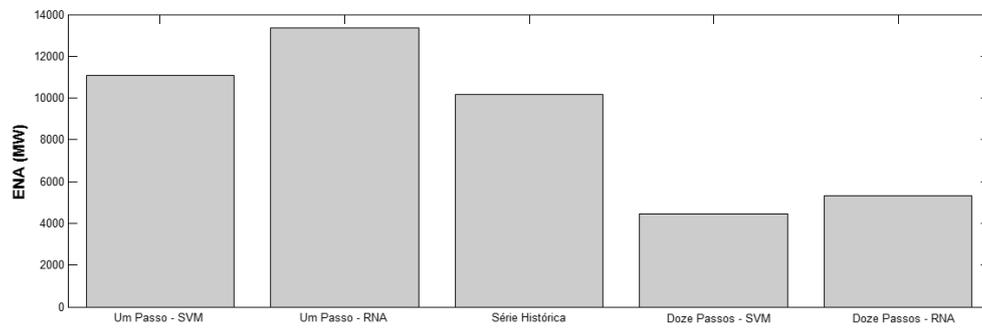
Curtose



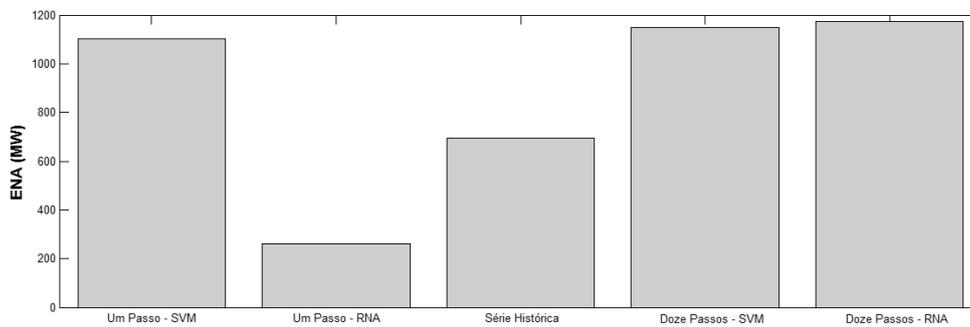
Desvio Padrão



Máximo



Mínimo



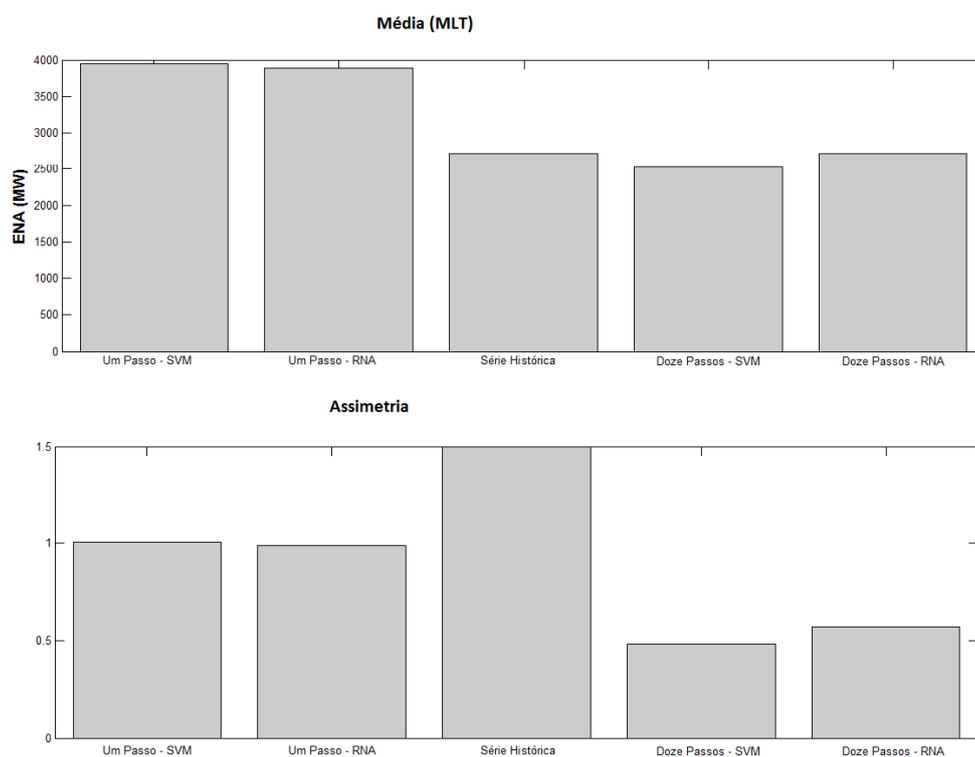


Figura 16- Média, assimetria, curtose, desvio-padrão, máximo, mínimo, mediana e coeficiente de variação entre as série real e as séries previstas de ENA para Um e Doze Passos Atrás

A análise das séries previstas em relação a série histórica mostra o comportamento dos previsores. Tanto o SVM quanto o RNA tiveram resultados bem semelhantes tanto na previsão de um passo quanto na previsão de doze passos atrás. Observa-se que quanto maior a quantidade de passos da previsão mais distante a série fica estatisticamente em relação à série histórica. Esse comportamento pode ser explicado pelo modelo não conseguir capturar com exatidão fenômenos e cheias que acontecem na série original.

5.4 Desempenho da previsão ENA em relação à vazão afluyente

Após a previsão da série de ENA histórica gerada ela foi desagregada para cada usina e seu RSME (Raiz Quadrada do Erro Quadrático Médio) foi calculado, segundo a fórmula:

$$RSME = \sqrt{\frac{\sum_{i=1}^n (X_i - \tilde{X}_i)^2}{n}} \quad (13)$$

onde X_i é o dado histórico, \tilde{X}_i o dado previsto e n a quantidade de dados.

Para realizar a análise da eficiência da previsão da série ENA pela técnica *Support Vector Machines* foram feitos experimentos de previsão utilizando a série histórica de vazão afluyente para cada usina. Assim como na previsão da série de ENA, a previsão de vazão afluyente de cada usina também foi realizada pelas Redes Neurais.

Os resultados podem ser considerados efetivos através da curva de erro RSME em relação ao desvio padrão. Portanto, a previsão deve preferencialmente se manter abaixo da linha do desvio e a tendência é a curva aumentar de encontro ou acima da linha do desvio de acordo com o aumento do número de passos. Esse fenômeno acontece pela alta instabilidade das vazões e a grande quantidade de variáveis que influenciam e agem sobre a série histórica.

Os resultados obtidos podem ser visualizados pela Figura 17 para a usina de Furnas, Figura 18 para usina de Mascarenhas de Moraes (Peixoto), Figura 19 para usina de Marimbondo e Figura 20 para a usina de Água Vermelha.

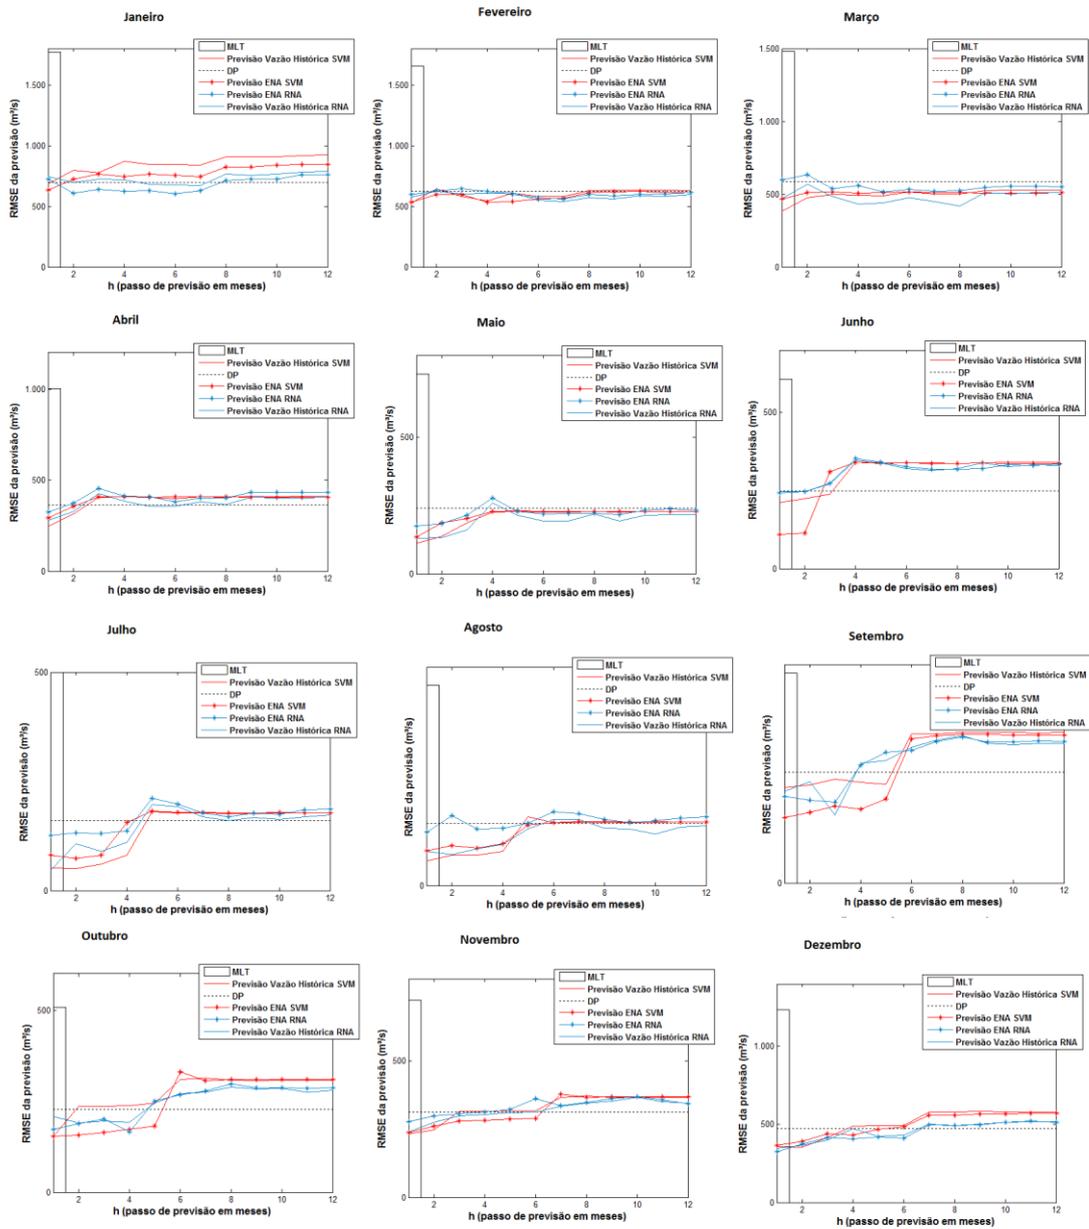


Figura 17 - RSME da previsão da série de ENA desagregada em relação à previsão de vazão da usina de Furnas

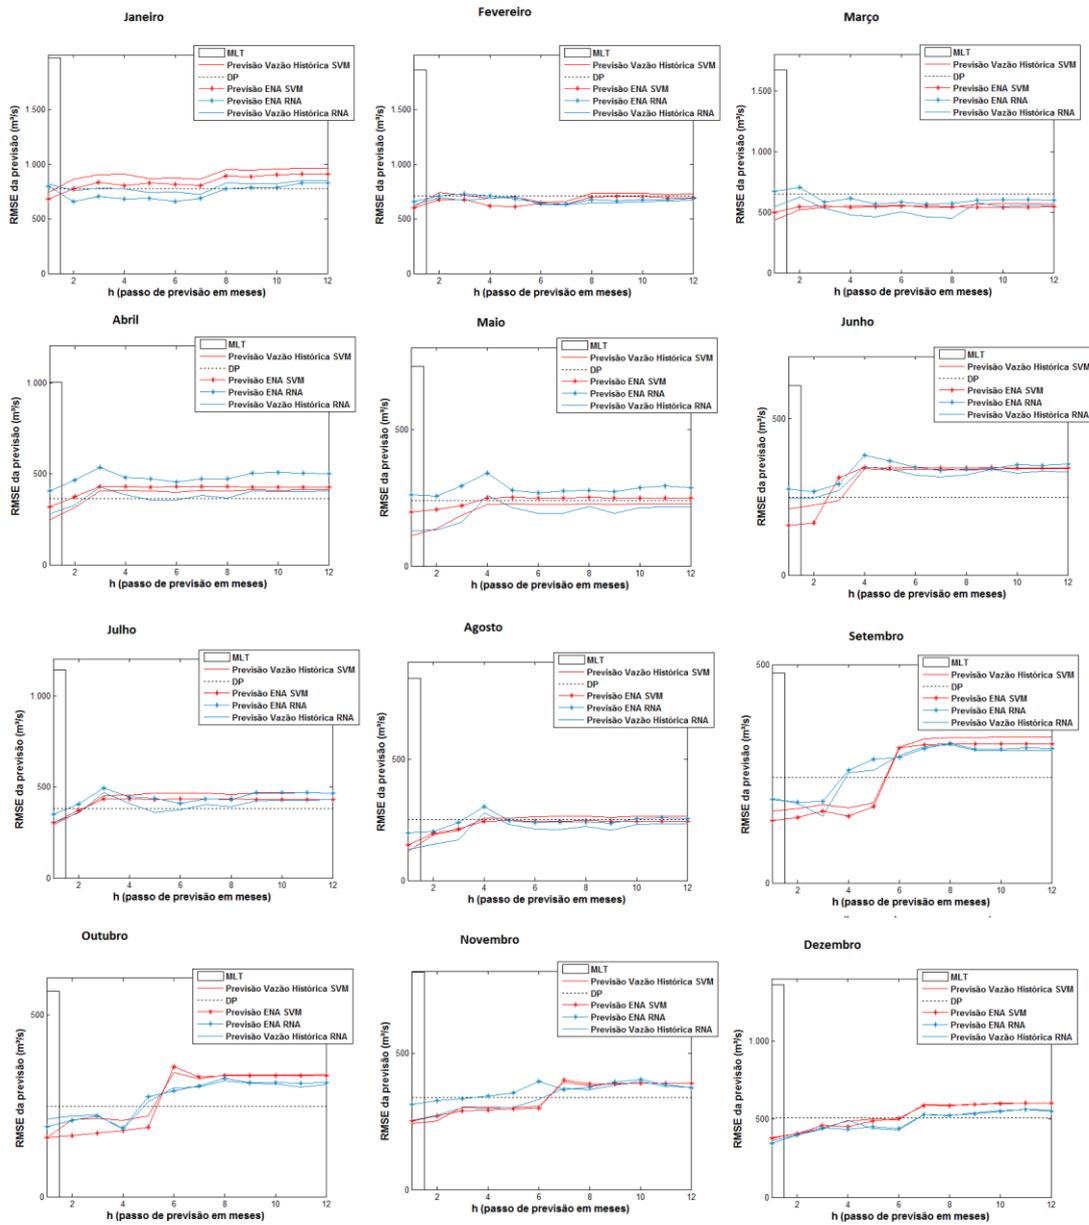


Figura 18 - RSME da previsão da série de ENA desagregada em relação à previsão de vazão da usina de Mascarenhas de Moraes (Peixoto)

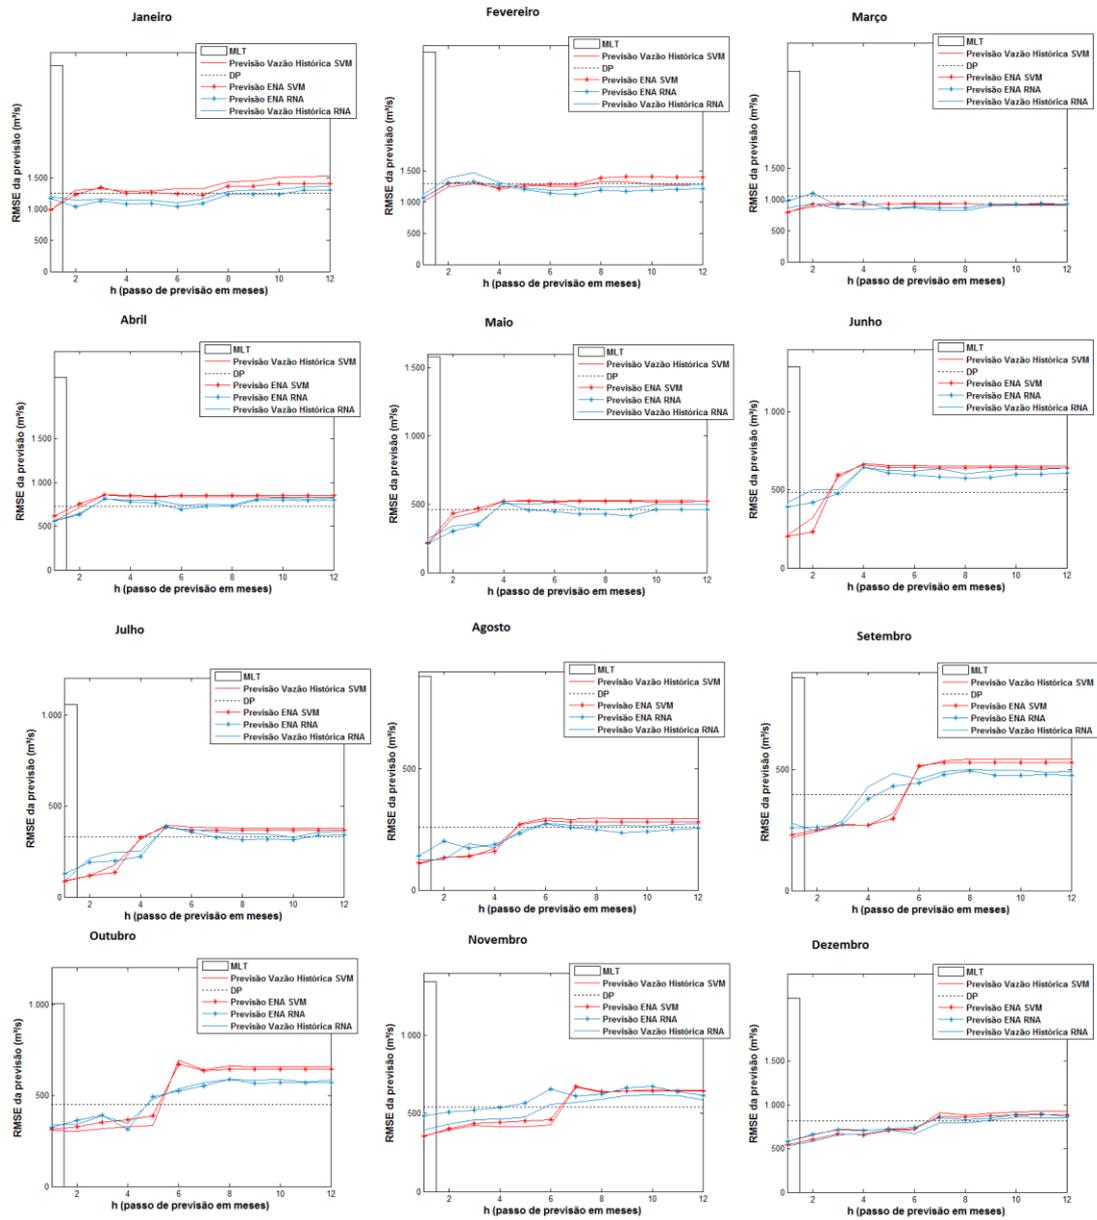


Figura 19 - RSME da previsão da série de ENA desagregada em relação à previsão de vazão da usina de Marimbondo

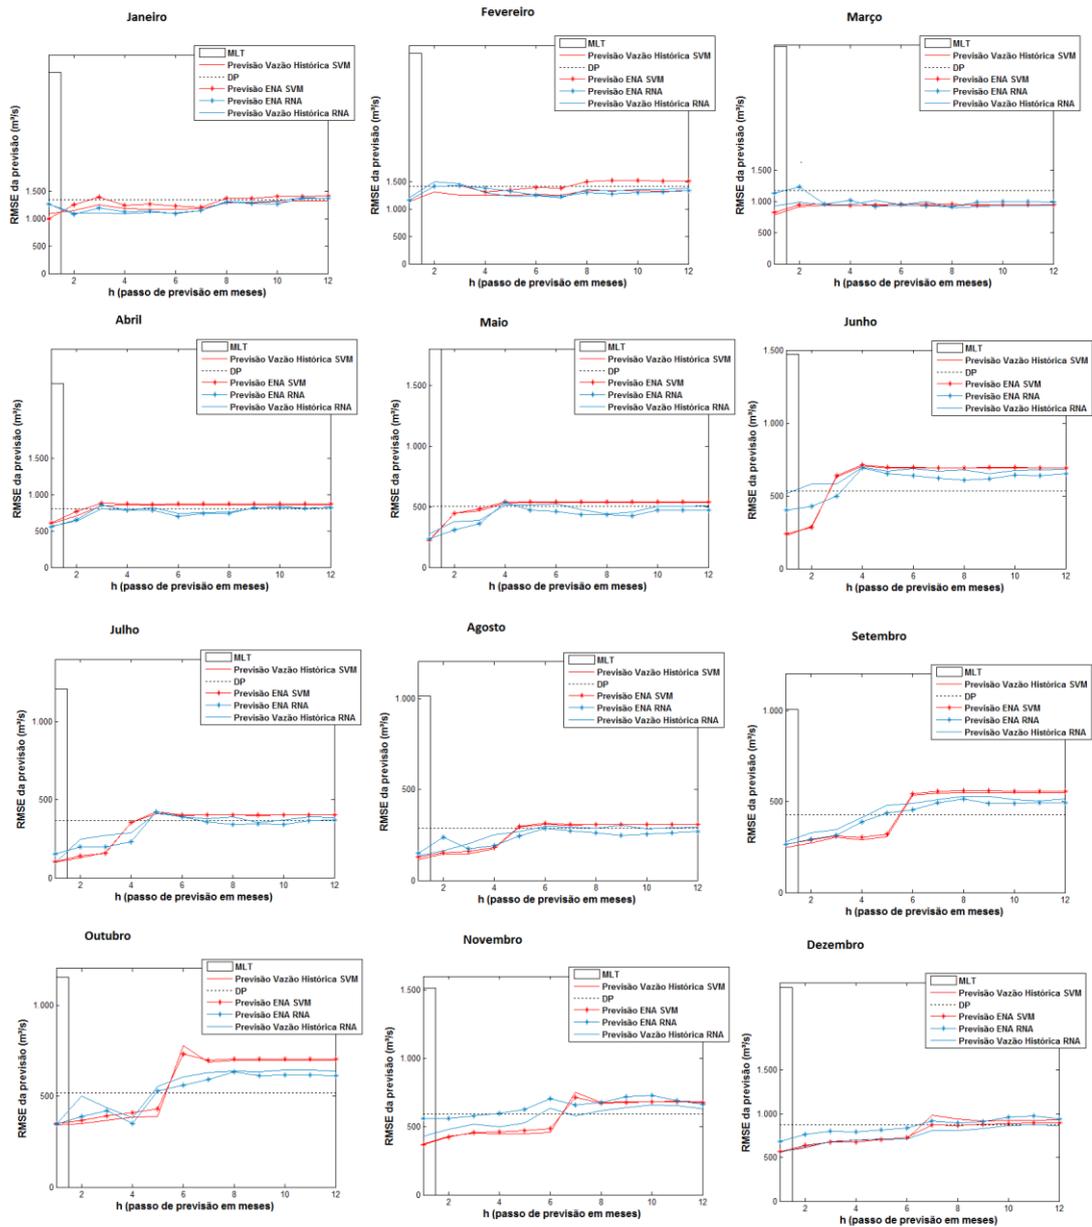


Figura 20 - RSME da previsão da série de ENA desagregada em relação à previsão de vazão da usina de Água Vermelha

Ao analisar os erros RSME pode-se notar a proximidade do comportamento das usinas em sequência: Furnas e Peixoto e Águas Vermelhas e Marimbondo. O comportamento da previsão utilizando o SVM foi similar ao comportamento da previsão utilizando as Redes Neurais e a série agregada ENA segue o mesmo padrão de previsão que a série prevista individual de vazão. Os erros foram

maiores quando os meses considerados foram meses de chuva: janeiro, fevereiro e março e foram diminuindo ao se aproximar dos meses mais secos.

Esse comportamento é esperado na previsão de vazões, pois os meses de chuva possuem historicamente uma grande variabilidade de valores e são muito suscetíveis a fenômenos naturais, como as secas e as cheias intensas.

As principais variáveis estatísticas obtidas nos resultados mostrados podem ser visualizadas pela Tabela 7 para a usina de Furnas, Tabela 8 para usina de Mascarenhas de Moraes (Peixoto), Tabela 9 para usina de Marimbondo e Tabela 10 para a usina de Água Vermelha.

Tabela 7 – Variáveis estatísticas para a previsão de vazão da usina de Furnas

Previsão/ Variável (valor na Série Histórica)	PREVISÃO UM PASSO ATRÁS				PREVISÃO DOZE PASSOS ATRÁS			
	SVM	RNA	SVM ENA	RNA ENA	SVM	RNA	SVM ENA	RNA ENA
<i>Média</i> 954,7	943,1	913,7	932,8	1029,71	910,1	933,1	860,4	1014
<i>Mediana</i> 715	882,6	718,7	745,8	800,5	756,3	748,1	634,3	814,3
<i>Máximo</i> 3621	3313,6	2730,8	2631,2	3057,2	1902	1975	1516	2001
<i>Mínimo</i> 210	20,0072	196,953	261,703	286,733	79,51	383,2	390,9	439,5
<i>Desvio Padrão</i> 650,6	20,0072	196,953	261,703	286,733	79,51	383,2	390,9	439,5
<i>Curtose</i> 5,1280	3,77900	3,83038	3,35477	3,49416	1,841	1,871	1,675	1,801
<i>Assimetria</i> 1,4798	0,94517	1,21765	1,00528	1,08578	0,406	0,599	0,480	0,571
<i>Coefficiente Variação</i> 0,6823	0,58396	0,61140	0,55691	0,57795	0,512	0,509	0,480	0,493

Tabela 8 - Variáveis estatísticas para a previsão de vazão da usina de Peixoto

Previsão/ Variável (valor na Série Histórica)	PREVISÃO UM PASSO ATRÁS				PREVISÃO DOZE PASSOS ATRÁS			
	SVM	RNA	SVM ENA	RNA ENA	SVM	RNA	SVM ENA	RNA ENA
<i>Média</i> 1050,2	882,8	935,3	1047,7	1155,47	785,9	931,9	966,4	1138
<i>Mediana</i> 791	704,6	718,0	835,6	896,5	632,0	745,9	777	913

<i>Máximo</i> 4064	3170,1	2879,6	2947,1	3421,09	1426	1944	1699	2240
<i>Mínimo</i> 225	195,8	178,9	293,1	320,8	338	393,2	437,9	491,8
<i>Desvio Padrão</i> 718,380	524,8	552,5	583,4	667,8	390,7	474	464,6	561,8
<i>Curtose</i> 5,177	4,21152	3,764	3,3547	3,49416	1,723	1,857	1,675	1,801
<i>Assimetria</i> 1,4795	1,16280	1,1630	1,0052	1,08578	0,528	0,595	0,480	0,571
<i>Coefficiente Variação</i> 0,6839	0,59446	0,5907	0,5569	0,57795	0,497	0,508	0,48	0,493

Tabela 9 - Variáveis estatísticas para a previsão de vazão da usina de Marimbondo

Previsão/ Variável (valor na Série Histórica)	PREVISÃO UM PASSO ATRÁS				PREVISÃO DOZE PASSOS ATRÁS			
	SVM	RNA	SVM ENA	RNA ENA	SVM	RNA	SVM ENA	RNA ENA
<i>Média</i> 2006,2	1918,9	1936,7	1868,18	2073,84	1730	1817	1723	2043
<i>Mediana</i> 1569	1528,4	1553,6	1493,65	1612,21	1237	1466	1270	1639
<i>Máximo</i> 7228	5795,1	5693,4	5269,55	6157,24	3233	3581	3037	4031
<i>Mínimo</i> 465	546,7	509,110	524,118	577,477	753	799,6	783	885,3
<i>Desvio Padrão</i> 1241,9208	1063,8	1071,13	1043,30	1201,92	845	893,7	830	1011
<i>Curtose</i> 4,7652178	4,07872	3,76021	3,35280	3,49142	1,855	1,805	1,702	1,824

<i>Assimetria</i> 1,3592602	1,15585	1,11641	0,99224	1,07393	0,512	0,545	0,465	0,556
<i>Coefficiente</i> <i>Variacão</i> 0,6182446	0,55282	0,55152	0,56017	0,58116	0,490	0,493	0,484	0,497

Tabela 10 - Variáveis estatísticas para a previsão de vazão da usina de Água Vermelha

Previsão/ Variável (valor na Série Histórica)	PREVISÃO UM PASSO ATRÁS				PREVISÃO DOZE PASSOS ATRÁS			
	SVM	RNA	SVM ENA	RNA ENA	SVM	RNA	SVM ENA	RNA ENA
<i>Média</i> 2245,9002	2103,8	2178,2	2131,4	2369,3	1949	2083	1960	2327
<i>Mediana</i> 1802	1630,6	1801,49	1700,0	1838,3	1399	1650	1445	1868
<i>Máximo</i> 7938	6395,6	5988,2	5995,4	7015,1	3885	3978	3456	4593
<i>Mínimo</i> 530	611,5	576,02	596,3	657,93	913,5	911,6	890,9	1008
<i>Desvio</i> <i>Padrão</i> 1339,122	1184,5	1152,80	1187,0	1369,3	1060	1016	945,1	1152
<i>Curtose</i> 4,572099	3,1272	3,22981	3,3547	3,4941	2,066	1,780	1,675	1,801
<i>Assimetria</i> 1,303692	1,0231	0,98574	1,0052	1,0857	0,828	0,568	0,480	0,571
<i>Coefficiente</i> <i>Variacão</i> 0,596519	0,56146	0,52776	0,5569	0,5779	0,542	0,486	0,480	0,493

As variáveis estatísticas mostradas reforçam a grande equivalência da previsão utilizando a série agregada ENA com a previsão utilizando a série de vazão individual de cada usina. Os valores como esperado comportam-se de forma mais próxima à série histórica quando visualizados na previsão de um passo atrás e

ao aumentar a quantidade de passos para doze os valores previstos se distanciam da série original.

5.5 Previsão utilizando Série Sintética

A previsão utilizando a série histórica de vazão pode não ser o suficiente para garantir a eficiência do modelo de previsão. Os motivos se devem ao fato da série histórica possuir poucos dados (de 1931 até o ano vigente dessa monografia) e não ser capaz de treinar um previsor de forma satisfatória.

Uma das formas de contornar esse problema é utilizando uma série sintética para a previsão. Essa série é feita através da série histórica, mantem as mesmas propriedades estatísticas da mesma e utiliza um valor aleatório para tentar reproduzir os fenômenos inesperados da vazão histórica.

Neste trabalho foram utilizadas séries sintéticas das quatro usinas trabalhadas: Furnas, Peixoto, Água Vermelha e Marimbondo. As séries possuíam 2200 anos cada e foi calculada a série ENA através delas. Tanto a previsão de um passo quanto a previsão até doze passos foram realizadas seguindo a metodologia para o previsor SVM sendo o período de treinamento do ano 1 até o ano 1199 e o de previsão dos anos 1200 até 2200, os resultados obtidos considerando a usina de Furnas podem ser observados na Figura 21.

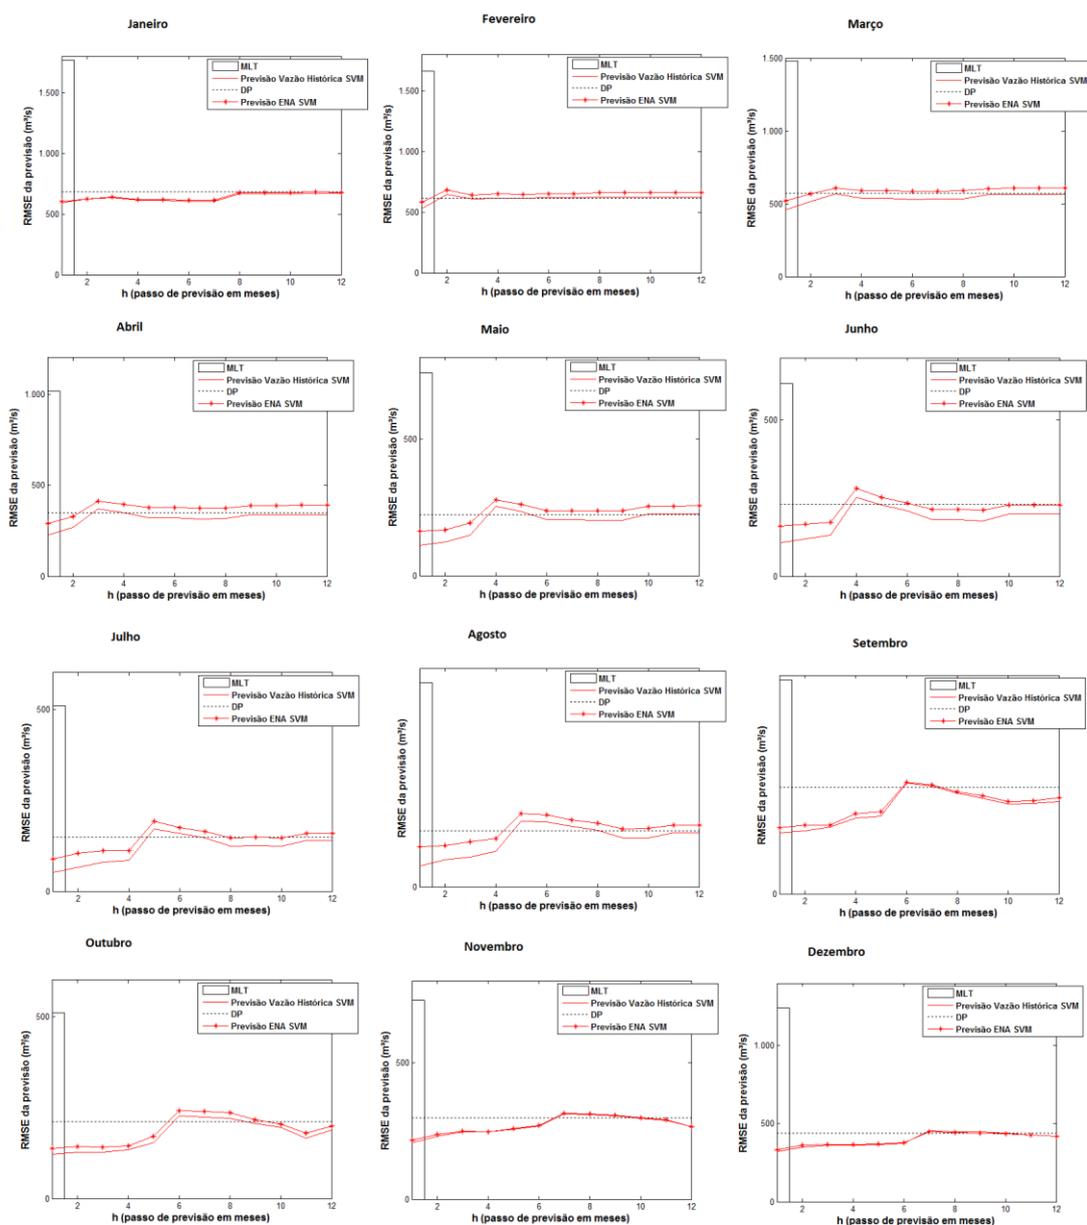


Figura 21 - RSME da previsão da série sintética de ENA desagregada em relação à previsão de vazão da usina de Marimbondo

Ao observar os resultados é notado o mesmo comportamento observado na previsão da série histórica: os erros RMSE obtidos com a previsão da série ENA são muito semelhantes àqueles obtidos através da previsão da série individual de vazão. Outra característica que se replicou foi a dificuldade encontrada ao aumentar os passos de previsão nos meses chuvosos, nesses casos o erro tende a ser maior que o desvio padrão ou muito próximo dele.

A série sintética, entretanto, por possuir uma grande quantidade de dados teve menos picos e variações drásticas nos erros e obteve uma curva menos nervosa e um aumento da quantidade de acertos da previsão.

6

Considerações Finais

Neste capítulo são apresentadas as considerações finais que foram obtidas a partir dos experimentos realizados nesta monografia e são discutidas propostas de trabalhos futuros acerca do problema discutido nesta monografia.

Este trabalho apresenta uma proposta de metodologia de previsão de vazões afluentes mensais utilizando a série agregada de Energia Natural Afluente. A previsão com a ENA é vantajosa por satisfazer todo um subsistema utilizando apenas uma série agregada, o que diminui o custo computacional além de fornecer uma dependência significativa entre as usinas que compõem a série.

A instância de teste compreendeu à um subsistema da Bacia do Grande, compreendendo as usinas de Furnas, Mascarenhas de Moraes (Peixoto), Marimbondo e Água Vermelha. O subsistema foi escolhido por apresentar usinas bem distribuídas pela bacia e ter tanto usinas de cabeceira quanto usinas jusantes.

A previsão foi dividida em três fases, sendo elas: treino, validação e teste. A fase de treino comportou dos anos de 1931 até o ano de 1979, a fase de validação e a fase de teste comportaram os períodos de 1980 até 2010. A distinção entre a fase de teste e a fase de validação se concentra no horizonte de previsão de cada uma, ou seja, a Previsão Um Passo Atrás realiza uma busca exaustiva de melhores parâmetros na fase de validação e a fase de teste compreendida pela Previsão Até Doze Passos Atrás aplica os resultados obtidos na fase anterior para a previsão de horizontes de dois até doze meses.

Os resultados obtidos nas previsões da série de Energia Natural Afluente foram realizados utilizando tanto a técnica de previsão *Support Vector Machines* quanto a de Redes Neurais Artificiais, tendo os SVM conseguido resultados superiores ou equivalente na maior parte das vezes. A série também foi submetida a uma análise das principais variáveis estatísticas e observou-se que a série tende a

se comportar de forma menos similar a série histórica quando o horizonte de previsão é aumentado.

Para testar a eficiência da série de ENA em relação à previsão individual de cada da previsão da série de vazão afluente foi feito um estudo comparativo sobre o RMSE de acordo com a evolução do horizonte de previsão e notou-se que ENA desagregada comporta-se de forma muito similar a previsão de série de vazão, possuindo resultados na maioria das vezes superior ou equivalente. A técnica *Support Vector Machines* também demonstrou ser superior a Rede Neural Artificial nesse experimento.

Como proposta de trabalhos futuros é possível aumentar a instância de teste para toda a Bacia do Rio Grande e combinar usinas de bacias diferentes para averiguar se o comportamento previsão da ENA permanece com resultados expressivos. Quanto à previsão é possível fazer um *ensemble* entre os previsores, ou seja, combiná-los de forma a conseguir uma previsão mais generalizada ao problema.

7 Referências Bibliográficas

- Atlas de Energia Elétrica do Brasil (ANEEL). Disponível em: <http://www.aneel.gov.br/>, Acessado: novembro/2011.
- Box, G. E. P. e Jenkins, G. M. (1976). Time Series Analysis: Forecasting and Control, number 1993, Holden-Day.
- Chang, C.-C. e Lin, C.-J. (2011). LIBSVM: A library for support vector machines, ACM Transactions on Intelligent Systems and Technology 2: 27:1-27:27. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- Cortes, C., Vapnik, V., Support Vector Networks, Machine Learning 20 (1995) pp. 273-297.
- de Braga, D., e Lima, M. D. C. e Salgado, R. M. (2011). An empirical analysis of mlp neural networks applied to streamflow forecasting, Latin America Transactions, IEEE 9(3): 295-301.
- de Braga, D., e Lima, M. D. C. e Salgado, R. M. (2011). An empirical analysis of mlp neural networks applied to streamflow forecasting, Latin America Transactions, IEEE 9(3): 295-301.
- Dibike, Y. e Solomatine, D. (2001). River flow forecasting using artificial neural networks, Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere 26(1): 1-7.
- Ehlers, R. (2005). Análise de Séries Temporais. Departamento de Estatística, Universidade Federal do Paraná.
- Fan, R., Chen, P. e Lin, C. (2005). Working set selection using second order information for training support vector machines, The Journal of Machine Learning Research 6: 1889-1918.
- Ferro, H. F. (2007), Otimização da Previsão de Carga Elétrica de Curto Prazo Utilizando Critérios de Similaridade entre Perfis de Consumo, Dissertação de Mestrado, Universidade Federal de Santa Catarina.

- Freitas, M. A. S. (1998), A decision support system for drought forecasting and reservoir management in northeast Brazil, in 'Congresso Brasileiro de Meteorologia'.
- Guilhon, L. (2002). Modelo heurístico de previsão de vazões naturais médias semanais aplicado à usina de Foz do Areia, PhD thesis, Universidade Federal do Rio de Janeiro.
- Gunn, S. (1998). Support vector machines for classification and regression, ISIS technical report 14.
- Gunn, S. R.; Brown, M.; Bossley, K. M. (1997), Network performance assessment for neurofuzzy data modelling *Advances in Intelligent Data Analysis*, vol. 1280, pp. 313-323.
- Hoff, J. (1983). A practical guide to Box-Jenkins forecasting, Lifetime Learning Publications Belmont, California.
- Jain, A. e Kumar, A. (2007). Hybrid neural network models for hydrologic time series forecasting, *Applied Soft Computing* 7(2): 585-592.
- Jang, J. (1993). Anfis: Adaptive-network-based fuzzy inference system, *Systems, Man and Cybernetics, IEEE Transactions on* 23(3): 665-685.
- Kennedy, J. e Eberhart, R. (1995). Particle swarm optimization, *Neural Networks, 1995. Proceedings., IEEE International Conference on*, Vol. 4, IEEE, pp. 1942-1948.
- Li, P., Kwon, H., Sun, L., Lall, U. e Kao, J. (2010). A modified support vector machine based prediction model on streamflow at the shihmen reservoir, taiwan, *International Journal of Climatology* 30(8): 1256-1268.
- Lima, A.R.G. (2002), Máquinas de Vetores Suporte na Classificação de Impressões Digitais, Dissertação de Mestrado, Universidade Federal do Ceará.
- Lorena, A. C.; Carvalho, A. C. P. L. F. (2007), Uma Introdução às Support Vector Machines, *Revista de Informática Teórica e Aplicada*, Vol. 14, No 2.
- Luna, I., Soares, S. e Ballini, R. (2007a). An adaptive hybrid model for monthly streamflow forecasting, *Fuzzy Systems Conference, 2007. FUZZ-IEEE 2007. IEEE International*, IEEE, pp. 1-6.

- Luna, I., Soares, S. e Ballini, R. (2007b). A constructive fuzzy system modeling for time series forecasting, *Neural Networks*, 2007. IJCNN 2007. International Joint Conference on, IEEE, pp. 2908–2913.
- Maity, R., Bhagwat, P. e Bhatnagar, A. (2010). Potential of support vector regression for prediction of monthly streamflow using endogenous property, *Hydrological Processes* 24(7): 917–923.
- Matriz de energia elétrica (2011). Disponível em: <http://www.aneel.gov.br/>, Acessado: novembro/2011.
- Maurer, E. P. e Lettenmaier, D. P. (2004). Potential effects of long-lead hydrologic predictability on missouri river main-stem reservoirs, *Journal of Climate* 17(1): 174–186.
- Mitchell, T.M. (1997). *Machine learning*. New York: McGraw-Hill.
- Modarres, R. (2007). Streamflow drought time series forecasting, *Stochastic Environmental Research and Risk Assessment* 21(3): 223–233.
- Operador Nacional do Sistema Elétrico (2011). Disponível em: <http://www.ons.org.br/>, Acessado: novembro/2011.
- Parrella, F. (2007), *Online Support Vector Regression*, Dissertação de Mestrado, University of Genoa.
- Ramos, T. P. (2011). *Modelo Individualizado de Usinas Hidrelétricas Baseado em Técnicas de Programação Não Linear Integrado com o Modelo de Decisão Estratégica*, Dissertação de Mestrado, Universidade Federal de Juiz de Fora.
- Ryan, Kevin, and Karen E. Bohlin. *Building Character in Schools*. 1st ed. San Fransico: Jossey-Bass, 1999. 5.
- Semolini, R. (2002), *Support Vector Machines, Inferência Transdutiva e o Problema de Classificação*, Tese de Mestrado, FEEC, Unicamp.
- Siqueira, H. V., Attux, R. e Lyra, C. (1998). Exploração de alternativas lineares para previsão de séries de vazões, *Computational Intelligence Techniques for Optimization and Data Modeling* 29(98): 9629–9644.
- Smola, A. J.; Schölkopf, B. (2000), *Sparse greedy matrix approximation for machine learning*, Citeseer.

- Smola, A. J.; Schölkopf, B. (2002), A tutorial on support vector regression, *Statistics and Computing* 14: 199-222.
- Soares Filho, S. (1987). Planejamento da operação de sistemas hidrotérmicos, *SBA-Controle e Automação* 1(2): 122-131.
- Vapnik, V., Chervonenkis, A. (1964), A note on one class of perceptrons. *Automation and Remote Control* 25.
- Vapnik, V., Chervonenkis, A. (1998), *Statistical learning theory*. Wiley-Interscience.
- Vapnik, V., Lerner (1963), Pattern recognition using generalized portrait method. *Automation and Remote Control* 24 pp. 774-78.
- Vladimir, V. e Vapnik, V. (1994). *The nature of statistical learning theory*.
- Wang, W., Nie, X. e Qiu, L. (2010). Support vector machine with particle swarm optimization for reservoir annual inflow forecasting, *Artificial Intelligence and Computational Intelligence (AICI)*, 2010 International Conference on, Vol. 1, IEEE, pp. 184-188.
- Yeh, W., Becker, L. e Zettlemoyer, R. (1982). Worth of inflow forecast for reservoir operation, *Journal of the Water Resources Planning and Management Division* 108(3): 257-269.
- Zealand, C., Burn, D. e Simonovic, S. (1999). Short term streamflow forecasting using artificial neural networks, *Journal of Hydrology* 214(1-4): 32-48.