

UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ
CAMPUS FOZ DO IGUAÇU
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA E COMPUTAÇÃO

DISSERTAÇÃO DE MESTRADO

**MODELO DE PREVISÃO DE CARGA DE
CURTÍSSIMO PRAZO APLICADO NA PREVISÃO DO
INTERCÂMBIO ENTRE ITAIPU E ANDE**

RODRIGO GONÇALVES PIMENTA

FOZ DO IGUAÇU

2019

Rodrigo Gonçalves Pimenta

**Modelo de Previsão de Carga de Curtíssimo Prazo
Aplicado na Previsão do Intercâmbio entre Itaipu e ANDE**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Computação como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica e Computação; Área de concentração: Sistemas Dinâmicos e Energéticos.

Orientador: Prof. Dr. Edgar Manuel Carreño Franco

Coorientador: Prof. Dr. Samuel Bellido Rodrigues

Foz do Iguaçu

Ficha de identificação da obra elaborada através do Formulário de Geração Automática do Sistema de Bibliotecas da Unioeste.

Pimenta, Rodrigo Gonçalves

Modelo de previsão de carga de curtíssimo prazo aplicado na previsão do intercâmbio entre Itaipu e ANDE / Rodrigo Gonçalves Pimenta; orientador(a), Edgar Carreño Franco; coorientador(a), Samuel Bellido Rodrigues, 2019.

85 f.

Dissertação (mestrado profissional), Universidade Estadual do Oeste do Paraná, Centro de Engenharias e Ciências Exatas, Programa de Pós-Graduação em Engenharia Elétrica e Computação, 2019.


1. Previsão de carga. 2. Operação. 3. SARIMA. I. Franco, Edgar Carreño. II. Rodrigues, Samuel Bellido. III. Título.

**Modelo de Previsão de Carga de Curtíssimo Prazo Aplicado
na Previsão do Intercâmbio entre Itaipu e ANDE**

Rodrigo Gonçalves Pimenta

Esta Dissertação de Mestrado foi apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e Computação e aprovada pela Banca Examinadora:

Data da defesa pública: 29/08/2019



Prof. Dr. Edgar Manuel Carreño Franco – (Orientador)

Universidade Estadual do Oeste do Paraná – UNIOESTE



Prof. Dr. Samuel Bellido Rodrigues – (Coorientador)

Universidade Tecnológica Federal do Paraná – UTFPR



Prof. Dr. Roberto Cayetano Lotero

Universidade Estadual do Oeste do Paraná – UNIOESTE



Prof. Dr. Emerson Lazzarotto

Universidade Estadual do Oeste do Paraná – UNIOESTE

Resumo

A previsão de demanda de energia elétrica é um problema de alta complexidade que faz parte do processo de planejamento da operação de um sistema elétrico, sendo influenciada por diversos fatores, tais como econômicos, localização geográfica, dia, hora, estações do ano e o clima.

A fim de planejar o despacho econômico de unidades geradoras de um sistema elétrico, é de fundamental importância antecipar a demanda a ser fornecida.

Em uma usina hidrelétrica a previsão de carga permite que o programa de geração seja elaborado de forma econômica e segura, considerando as restrições operativas vigentes, associadas à disponibilidade energética, à reserva de potência operativa e ao controle dos níveis montante e jusante.

Assim sendo, erros na previsão de carga implicam em desvios significativos no programa de geração da Central Hidrelétrica de Itaipu, o qual se traduz em dificuldades para as equipes de tempo real, impactando negativamente nos requisitos de qualidade de atendimento aos Sistemas Elétricos do Brasil e do Paraguai.

Este trabalho aplica um método de previsão de carga de curtíssimo prazo que visa reduzir os desvios significativos observados durante a execução do programa de intercâmbio entre Itaipu e ANDE.

O método é baseado no conceito de séries temporais de Box & Jenkins na obtenção de modelos SARIMA, aproveitando-se da característica sazonal das séries temporais formadas pelas observações horárias do intercâmbio entre Itaipu e ANDE.

O método proposto é testado para aplicação na execução da programação diária hidroenergética de Itaipu, apresentando resultados satisfatórios com erros médios na ordem de 5%, melhorando o método atualmente utilizado.

Palavras-chave: operação de hidrelétrica, previsão de carga no curtíssimo prazo, séries temporais e SARIMA.

Abstract

The electric load forecast is a problem of relevant complexity that integrates the planning and operation process of an electric power system, being influenced by several factors, such as economy, geography position, day, time, seasons and weather conditions.

In order to execute the program of an electric power system with efficiency it is very important to be able to anticipate the demand to be supplied.

Considering the operation of a hydroelectric power plant, the main objective of the load forecast is to provide input to develop the generation schedule program with economy and safety, taking into account the current operational restrictions, associated with energy availability, active power reserve and control of the upstream and downstream levels.

Thus, significant deviations in the generation program of the Itaipu hydroelectric power dam may cause difficulties for the real-time operation teams, impacting the quality requirements for the Brazilian and Paraguayan Electric Power Systems.

This paper presents a very short-term load forecasting (VSTLF) methodology applied to solve the problem when significant deviations are observed in the power exchange program between Itaipu e ANDE.

The method is based on the Box & Jenkins time series concept in obtaining SARIMA models, taking in advantage of the seasonal characteristics of the time series formed by the hourly observations of the power exchange between Itaipu e ANDE.

The proposed methodology is applied in Itaipu's daily hydroenergetic schedule, presenting satisfactory results with average errors of around 5%, improving the method currently used.

Key-words: hydroelectric power plant operation, very short-term load forecasting, time series and SARIMA.

Revelemo-nos mais por atos do que por palavras.

Theodomiro C. Santiago

Agradecimentos

Primeiramente, agradeço ao Grande Arquiteto do Universo, força onipresente que acompanhou-me durante todos os momentos desta árdua jornada.

Agradeço ao meu pai, Luiz Alberto Pimenta e a minha mãe, Rejane Gonçalves Pimenta que nunca mediram esforços para me proporcionar todas as condições necessárias para que eu pudesse chegar até aqui e que sempre foram presentes em minha vida, sendo exemplos de todas as minhas ações. Agradeço também a minha irmã, a engenheira de produção Fabíola Gonçalves Pimenta, pelas mensagens e palavras de incentivo, muito importantes para manter-me motivado.

Agradeço a minha querida esposa, Cristiane P. S. Fraga Pimenta e aos meus amados filhos Cauê Fraga Pimenta, Guilherme Fraga e Gustavo Fraga, que foram minha principal fonte de motivação e incentivo.

Externo também meus agradecimentos aos colegas Gionei Gaio e Marcos Ricardo Müller pelas explanações iniciais sobre o tema e pela parceria na submissão de artigos. Aproveito a citação, para agradecer a todos os demais colegas do curso de mestrado da UNIOESTE, profissionais que concentram todas as qualidades para atingir o sucesso em suas respectivas carreiras profissionais.

Agradeço meus colegas de trabalho na Itaipu Binacional, os engenheiros Rafael José de Andrade e Ricci E. Oviedo Sanabria, da Divisão de Programação e Estatística, bem como o colega Marcelino J. M. Fariña Jara, da Divisão de Hidrologia, pelas informações e apoio na contextualização do problema.

Ao amigo Anastacio Sebastian Arce Encina, orientador de dezenas de trabalhos acadêmicos e profissionais sobre operação e planejamento hidroenergético, externo meus agradecimentos pelo incentivo, motivação e pertinentes sugestões.

Manifesto meus agradecimentos ao Superintendente de Operação da Itaipu, o engenheiro Rui Jovita, pelo apoio incondicional, sendo uma fonte de inspiração para todos os profissionais da empresa, devido toda a sua determinação para atingir seus objetivos.

Finalmente, agradeço o Professor Edgar Manuel Carreño Franco, da UNIOESTE e o Professor Samuel Bellido Rodrigues, assim como os demais professores do Departamento de Matemática da UTFPR Campus Medianeira, em razão das orientações, paciência e disponibilidade de tempo que foram fundamentais para o desenvolvimento da solução do problema apresentado.

Sumário

Lista de Figuras	12
Lista de Tabelas	14
Lista de Símbolos	15
Lista de Siglas e Abreviaturas	17
1 Problema	19
1.1 Objetivos	28
1.1.1 Objetivo Geral.....	28
1.1.2 Objetivos Específicos.....	28
1.2 Estrutura Do Trabalho.....	29
2 Revisão Bibliográfica	31
2.1 Métodos de Previsão de Carga.....	31
2.1.1 Regressão Linear Múltipla.....	32
2.1.2 Amortecimento Exponencial.....	32
2.1.3 Séries Temporais Estocásticas.....	33
2.1.4 Redes Neurais Artificiais.....	34
2.1.5 Máquinas de Vetores de Suporte.....	36
3 Materiais e Métodos	41
3.1 Séries Temporais.....	41
3.2 Metodologia Box e Jenkins.....	43
3.2.1 Modelo Autoregressivo (AR).....	43
3.2.2 Modelo Média Móvel (MA).....	44
3.2.3 Modelo Autoregressivo Média Movel (ARMA).....	44
3.2.4 Modelo Autoregressivo Média Movel Integrado (ARIMA).....	45
3.2.5 Modelo Sazonal.....	45
3.3 Estágios do Método Box e Jenkins.....	46
3.3.1 Fase de identificação.....	47
3.3.2 Fase de estimação.....	48
3.3.3 Fase de verificação.....	49
3.4 Previsão Automática de Modelos ARIMA.....	49
3.5 Intervalo de Confiança.....	51
3.6 Dados utilizados.....	52

4 Testes e Resultados	59
5 Conclusão	69
Referências Bibliográficas	71
Apêndice A Parâmetros dos Modelos	75
Anexo A Modelo de Previsão de Carga de Curto Prazo para o Intercâmbio entre Itaipu e ANDE apresentado no XVIII ERIAC	77
Anexo B Short Term Load Forecasting for Power Exchange Between Brazil e Paraguay apresentado no VII SBSE	87

Lista de Figuras

Figura 1.1: Esquema simplificado do Sistema Elétrico Itaipu.....	21
Figura 1.2: Mapa indicando a localização da régua R11.....	22
Figura 1.3: Comparação do nível projetado e observado na régua R11.....	23
Figura 1.4: Curva colina de uma turbina hidráulica.....	24
Figura 1.5: Curvas das faixas de eficiência das unidades geradoras de Itaipu.....	25
Figura 1.6: Plano de despacho ótimo programado.....	26
Figura 1.7: Plano de despacho ótimo realizado.....	26
Figura 1.8: Histograma dos desvios do intercâmbio entre Itaipu e ANDE.....	27
Figura 2.1: Categorias das previsões de carga de acordo com o horizonte de previsão.....	31
Figura 2.2: Neurônio Artificial.....	35
Figura 2.3: Arquitetura MLP de uma rede neural.....	36
Figura 2.4.a: Conjunto de dados não linear.....	37
Figura 2.4.b: Fronteira não linear no espaço de entradas.....	37
Figura 2.4.c: Fronteira linear no espaço de características.....	37
Figura 2.5: Dados de temperatura de Assunção/PY.....	38
Figura 3.1: Série original que representa o intercâmbio Itaipu e ANDE.....	42
Figura 3.2: Série do intercâmbio Itaipu e ANDE destacando a sazonalidade.....	42
Figura 3.3: Filtro modelo ARIMA.....	43
Figura 3.4: Fluxograma dos estágios de Box&Jenkins.....	46
Figura 3.5: Representação de um IC para μ , com $\gamma = 0,95$ e σ^2 conhecido.....	52
Figura 3.6: Amostra da série original.....	53
Figura 3.7: Série intercâmbio entre Itaipu e ANDE para Sábados.....	53
Figura 3.8: Série intercâmbio entre Itaipu e ANDE para Domingos.....	54
Figura 3.9: Série intercâmbio entre Itaipu e ANDE para dias úteis.....	54
Figura 3.10: Série completa do intercâmbio entre Itaipu e ANDE para dia útil.....	55
Figura 3.11: Série completa do intercâmbio entre Itaipu e ANDE para sábado.....	56
Figura 3.12: Série completa do intercâmbio entre Itaipu e ANDE para domingo.....	56
Figura 4.1: Intercâmbio entre Itaipu e ANDE observado, programado e o modelo proposto para um cenário de dia útil.....	62

Figura 4.2: Intercâmbio entre Itaipu e ANDE observado, programado e o modelo proposto para um cenário de dia de Sábado.	62
Figura 4.3: Intercâmbio entre Itaipu e ANDE observado, programado e o modelo proposto para um cenário de dia de Domingo.	63
Figura 4.4: Projeção do nível da régua R11 observada, programada e com o modelo proposto.	64
Figura 4.5: Readequação no plano de despacho ótimo alterado.....	65
Figura 4.6: Intercâmbio entre Itaipu e ANDE observado, programado e do modelo proposto para um cenário de dia útil e intervalo de confiança.	66
Figura 4.7: Intercâmbio entre Itaipu e ANDE observado, programado e do modelo proposto para um cenário de Domingo e intervalo de confiança	66

Lista de Tabelas

Tabela 1.1: Exemplo de uma programação diária dos intercâmbios de Itaipu com Eletrobras e ANDE.	20
Tabela 1.2: Exemplo de uma programação de defluência diária de Itaipu.	21
Tabela 1.3: Nível e variações observadas e projetadas na régua R11.	23
Tabela 4.1: Modelos para o horizonte de 24 horas.	60
Tabela 4.2: Modelos para o horizonte de 18 horas.	60
Tabela 4.3: Modelos para o horizonte de 12 horas.	60
Tabela 4.4: Modelos para o horizonte de 6 horas.	60

Lista de Símbolos

P_G	Potência produzida por uma unidade geradora em MW
H_l	Queda líquida em m
Q	Vazão turbinada m^3/s
η_T	Rendimento da turbina
η_G	Rendimento do gerador
H_b	Queda bruta em m
H_p	Perda hidráulica no conduto forçado em m
k	Constante de perda hidráulica
Y_t	Variável dependente
v_t	Vetor de variáveis independentes
ε_t	Desvios entre as observações e as estimativas
z_t	Demanda observada no tempo t
$\hat{z}_t$	Demanda estimada no tempo t
ϕ_i	Coefficientes dos modelos autorregressivos AR.
p	Ordem dos modelos AR
θ_i	Coefficientes dos modelos média móvels MA
q	Ordem dos modelos MA
B	Operador defasador
d	Ordem de diferenciação dos modelos ARIMA
$\hat{\sigma}_p^2$	Estimador de verossimilhança

Lista de Siglas e Abreviaturas

AIC	Akaike Information Criterion
ANDE	Administración Nacional de Eletricidad
APEmax	Maximum Absolute Percentage Error
AR	Modelo Autorregressivo
ARIMA	Modelo Autorregressivo Integrado de Média Móvel
ARMA	Modelo Autorregressivo de Média Móvel
EMV	Estimador de Máxima Verossimilhança
EQM	Erro Quadrático Médio
fac	Função de autocorrelação
facp	Função de autocorrelação parcial
FLV	Função de Log-Verossimilhança
MA	Modelo Média Móvel
MAPE	Mean Absolute Percentage Error
MLP	Multilayer Perceptron
OBS	Intercâmbio observado
PDO	Programa Diário de Operação
PLD	Preço da Liquidação das Diferenças
PROG	Intercâmbio programado
RNA	Rede Neural Artificial
SARIMA	Modelo Sazonal Autorregressivo Integrado de Médias Móvel
SARMA	Modelo Sazonal Autorregressivo de Médias Móvel
SVM	Support Vector Machine
SVR	Support Vector Regression
SVRM	Support Vector Regression Machine

Capítulo 1

Problema

Itaipu é uma central hidrelétrica binacional que tem como sócios Eletrobras (Brasil) e ANDE (Paraguai). Foi construída a partir de 1974 e está localizada no Rio Paraná, na fronteira entre Brasil e Paraguai, próxima a cidade brasileira de Foz do Iguaçu e a cidade paraguaia de Hernandarias. Iniciou sua produção em 1984 e possui 20 unidades geradoras com potência de 700MW, totalizando uma potência instalada de 14.000MW, sendo a segunda maior hidrelétrica do mundo. Desde o início da operação, Itaipu já produziu mais de 2,6 bilhões de Megawatts-hora e atualmente é responsável pelo suprimento de aproximadamente 15% da energia elétrica para o Brasil e de mais de 90% para o Paraguai.

A casa de força de Itaipu é dividida em dois setores, um operando na frequência de 50Hz e outro operando na frequência de 60Hz, cada um com 10 unidades geradoras. A energia gerada no setor de 60Hz é transmitida para o Sistema Elétrico Brasileiro, utilizando o Sistema de 765kV de Furnas e uma linha de 525kV da Copel, a partir da subestação de Foz do Iguaçu. A energia gerada no setor de 50Hz é escoada para o Sistema Elétrico Paraguaio, utilizando quatro linhas de 220kV e uma linha de 500kV, pertencentes a ANDE (Administración Nacional de Electricidad). O montante de energia que o Paraguai não utiliza é escoado para o Sistema Elétrico Brasileiro, a partir da subestação de Foz do Iguaçu no Paraná, utilizando o sistema de corrente contínua em 600kVcc Foz do Iguaçu-Ibiúna, de propriedade de Furnas.

O desenvolvimento deste trabalho foi motivado pela necessidade de obtenção de um modelo de previsão de carga de curtíssimo prazo para auxiliar a equipe de operação em tempo real de Itaipu na tomada de decisões frente a eventuais desvios da programação do intercâmbio entre Itaipu e ANDE.

A etapa de previsão de carga exerce uma influência muito importante dentro do processo de planejamento de curto prazo de uma usina hidrelétrica, impactando no resultado das funções descritas a seguir (Shahidehpour, M., Yamin, H. & Li, Z., 2002).

- **Programa de Geração:** o programa de geração de uma usina hidrelétrica, contempla um programa de defluência que deve ser executado com o principal objetivo de controlar os níveis montante e jusante da usina. Desta forma, eventuais desvios na programação podem comprometer a segurança da barragem, além de causar transtornos à navegabilidade e problemas sociais na ocorrência de cheias que afetam a população que reside às margens do rio.

- **Segurança do Sistema Elétrico:** uma boa acurácia na previsão de carga pode prover o Sistema Elétrico de maior segurança, pois as medidas operativas preventivas e corretivas, frente a eventuais contingências, tornam-se mais eficientes.
- **Reserva de Potência Operativa:** a reserva de potência é dimensionada para manter o equilíbrio entre carga e geração, prevendo-se um acréscimo súbito na carga do Sistema Elétrico ou a perda de determinado montante de geração. Assim, diferenças na previsão de carga pode comprometer o atendimento aos consumidores.

Os montantes de energia destinados ao Brasil e ao Paraguai são definidos em intervalos de trinta minutos durante o processo de elaboração do Programa Diário da Operação (PDO) de Itaipu, resultando na Tabela 1.1 que apresenta, de forma separada, o intercâmbio de Itaipu com a Eletrobras nos setores de 50Hz e 60Hz, bem como o intercâmbio entre Itaipu e ANDE. Adicionalmente, a última coluna da Tabela 1.1 apresenta o resultado da soma do intercâmbio entre Itaipu e Eletrobras em 50Hz e o intercâmbio entre Itaipu e ANDE, formando a geração total do setor de 50Hz da Usina de Itaipu (Andrade, R. J. e Sanabria, R. E. O., 2017).

Tabela 1.1 – Exemplo de uma programação diária dos intercâmbios de Itaipu com Eletrobras e ANDE

PROGRAMACIÓN DIÁRIA DE LA OPERACIÓN PROGRAMAÇÃO DIÁRIA DA OPERAÇÃO						
Hora		INTERCÂMBIO / FORNECIMENTO ENERGÉTICO (MWh/h)				
		ELETROBRÁS			ANDE	ANDE
Início	Fim	60Hz	50Hz	60+50Hz		+ 50Hz
0:00	0:30	4.250	2.500	6.750	1.222	3.722
0:30	1:00	4.250	2.500	6.750	1.222	3.722
1:00	1:30	3.750	2.500	6.250	1.088	3.588
1:30	2:00	3.550	2.500	6.050	1.088	3.588
2:00	2:30	3.250	1.700	4.950	1.055	2.755
2:30	3:00	3.250	1.700	4.950	1.055	2.755
3:00	3:30	3.250	1.700	4.950	1.020	2.720
3:30	4:00	3.350	1.700	5.050	1.020	2.720
4:00	4:30	3.250	1.700	4.950	1.007	2.707
4:30	5:00	3.250	1.700	4.950	1.007	2.707
5:00	5:30	3.250	1.700	4.950	1.014	2.714
5:30	6:00	3.250	1.700	4.950	1.014	2.714
6:00	6:30	3.250	1.700	4.950	1.063	2.763

A geração total do setor de 50Hz atende o intercâmbio com a ANDE e o intercâmbio com a Eletrobras, transmitido pelo elo de corrente contínua, limitados à disponibilidade do referido setor desta usina, como pode ser observado na Figura 1.1. Portanto, desvios significativos na previsão do intercâmbio com a ANDE pode comprometer o atendimento ao Sistema Elétrico Brasileiro, ou reduzir a eficiência da produção de energia da usina, pois uma redução não prevista no intercâmbio entre o Itaipu e ANDE pode ter como consequência uma disponibilidade de energia não utilizada.




Figura 1.1 - Esquema simplificado do Sistema Elétrico Itaipu. Fonte: Itaipu

Outro aspecto importante na operação de uma usina hidrelétrica é o controle da vazão defluente e, conseqüentemente, dos níveis montante e jusante da usina. Este controle é necessário para garantir a preservação do meio ambiente, a navegabilidade e demais usos múltiplos da água. Assim, como resultado da definição do programa de geração da usina, tem-se um programa diário de defluência que é a soma da vazão turbinada e da vazão vertida. Na Itaipu, em particular, a vazão turbinada total é o resultado das vazões turbinadas dos setores de 50Hz e 60Hz, conforme mostra a Tabela 1.2.

Tabela 1.2 – Exemplo de uma programação de defluência diário de Itaipu

Dia	1/01	GERERAÇÃO			TURBINADO			VERT.	DEFL.
		50 Hz	60 Hz	TOTAL	50 Hz	60 Hz	TOTAL		
Hora	Fim	Mwmedios			m³/s			TOTAL	TOTAL
00:00	00:30	5.132	4.163	8.835	4.726	3.884	8.609	-	8.609
00:30	01:00	5.132	4.213	9.284	4.728	3.949	8.677	-	8.677
01:00	01:30	5.138	4.163	9.298	4.734	3.887	8.621	-	8.621
01:30	02:00	4.938	3.963	9.054	4.543	3.654	8.197	-	8.197
02:00	02:30	4.593	3.713	8.451	4.218	3.406	7.625	-	7.625
02:30	03:00	4.593	3.863	8.139	4.220	3.545	7.766	-	7.766
03:00	03:30	4.571	3.763	8.085	4.193	3.448	7.641	-	7.641
03:30	04:00	4.571	3.763	8.094	4.194	3.449	7.642	-	7.642
04:00	04:30	4.575	3.763	7.915	4.194	3.447	7.641	-	7.641
04:30	05:00	4.575	3.763	7.900	4.194	3.447	7.641	-	7.641
05:00	05:30	4.623	3.863	7.897	4.242	3.538	7.780	-	7.780
05:30	06:00	4.623	3.513	7.887	4.237	3.231	7.469	-	7.469
06:00	06:30	4.792	3.263	7.870	4.412	3.033	7.444	-	7.444
06:30	07:00	4.242	3.013	7.220	3.877	2.836	6.713	-	6.713
07:00	07:30	4.137	3.013	7.128	3.784	2.832	6.615	-	6.615
07:30	08:00	4.437	3.013	7.342	4.040	2.833	6.873	-	6.873
08:00	08:30	4.453	3.163	7.378	4.050	2.946	6.995	-	6.995
08:30	09:00	4.453	3.513	7.368	4.054	3.219	7.273	-	7.273
09:00	09:30	4.532	3.513	7.571	4.128	3.220	7.348	-	7.348
09:30	10:00	4.532	3.713	7.794	4.131	3.387	7.518	-	7.518
10:00	10:30	5.309	3.863	8.519	4.881	3.536	8.417	-	8.417
10:30	11:00	5.709	3.863	8.876	5.232	3.542	8.774	-	8.774
11:00	11:30	6.301	3.863	9.540	5.891	3.556	9.447	-	9.447
11:30	12:00	6.301	3.863	9.719	5.894	3.557	9.450	-	9.450

Um acordo firmado entre Argentina, Brasil e Paraguai, estabelece que, em um intervalo de 24 horas, a defluência proveniente da Itaipu não pode provocar variações superiores a dois metros no nível do rio Paraná, medido por uma régua denominada R11, situada à jusante da usina, na margem paraguaia do Rio Paraná, na confluência deste rio com o rio Iguaçu, como mostra a Figura 1.2 (Fajardo, 2004).



Figura 1.2 – Mapa indicando a localização da régua R11

Para auxiliar a equipe de execução da operação a cumprir rigorosamente o acordo, tem-se um aplicativo que calcula e apresenta a projeção do nível a ser controlado, tendo como base a programação diária de operação. Os cálculos são realizados automaticamente em intervalos de uma hora, ou sob ação da equipe de execução da operação (Manual Interno de Referência das Grandezas Hidroenergéticas de Itaipu, 2017).

Como exemplo, a Tabela 1.3 apresenta os resultados do aplicativo calculados às 6:00 de um determinado dia. Os resultados mostram os níveis medidos até momento do cálculo, apresentados na cor amarela, bem como a projeção ao longo do dia. As principais informações constantes na tabela são a vazão do rio Paraná no local da régua R11 (*Caudal R11*), o nível do

rio no mesmo local (*Nível em R11*) e as variações em função dos níveis medidos e projetados (*Variacion Nivel em R11*).

Tabela 1.3 – Nível e variações observadas e projetadas na régua R11

Dia	1/01	CAUDAL	NIVEL	VARIACION NIVEL EN R11			
Hora	Hora	R11	R11	TOTAL		ITAIPU	
Início	Fim		m	Horár.	Diária	Horár.	Diária
00:00	00:30	10.845	98,49				
00:30	01:00	10.861	98,51	0,03	1,05	0,04	-0,65
01:00	01:30	10.914	98,58				
01:30	02:00	10.915	98,58	0,07	1,12	0,09	0,59
02:00	02:30	10.817	98,45				
02:30	03:00	10.827	98,47	-0,12	1,01	-0,11	0,48
03:00	03:30	10.725	98,33				
03:30	04:00	10.737	98,35	-0,12	0,89	-0,09	0,38
04:00	04:30	10.641	98,22				
04:30	05:00	10.665	98,25	-0,10	0,79	-0,06	-0,34
05:00	05:30	10.569	98,12				
05:30	06:00	10.596	98,16	-0,09	0,70	-0,04	-0,38
06:00	06:30	10.489	98,01				
06:30	07:00	10.524	98,06	-0,10	-0,63	-0,09	-0,47
07:00	07:30	10.293	97,75				
07:30	08:00	10.283	97,73	-0,33	-0,96	-0,23	-0,70
08:00	08:30	10.074	97,44				
08:30	09:00	10.081	97,45	-0,28	-1,24	-0,12	-0,82
09:00	09:30	10.089	97,46				
09:30	10:00	10.092	97,47	0,02	-1,22	-0,06	-0,88
10:00	10:30	10.168	97,57				
10:30	11:00	10.183	97,59	0,13	-1,10	0,10	-0,78
11:00	11:30	10.369	97,85				
11:30	12:00	10.386	97,87	0,28	-0,82	0,25	-0,53

Como o nível jusante da usina sofre influência direta da vazão defluente, resultante do programa de intercâmbio, desvios da previsão de intercâmbio resulta em erros na projeção do nível a ser controlado, como mostra a Figura 1.3. A citada figura apresenta a projeção calculada em função da previsão de intercâmbio utilizada na data em questão (PROG), comparando-a com o nível medido na régua (OBS). Nota-se um desvio 0,71 metro entre a projeção e o nível observado, o que pode conduzir a equipe de tempo real a uma omissão nas ações de controle, ou até mesmo a tomar ações equivocadas.




Figura 1.3 – Comparação do nível projetado e observado na régua R11

Um aspecto não menos importante da previsão de carga está presente na determinação do plano ótimo de despacho de unidades geradoras, o qual, em uma central hidrelétrica, busca um ponto de operação para as unidades que resulte em elevado rendimento, reduzindo o consumo de água (Gross, G. & Galiana, F. D., 1987).

Em uma usina hidrelétrica, a potência produzida P_G [MW] por uma unidade geradora é função da queda líquida H_l [m], da vazão turbinada Q [m³/s], do rendimento da turbina η_T e do rendimento do gerador η_G .

$$P_G = 9,81 \times \eta_T \times \eta_G \times H_l \times Q \times 10^{-3} \quad (1.1)$$

O rendimento da turbina (η_T) é uma função não linear dependente da vazão turbinada e da queda líquida. Esta relação determina a curva de rendimento da turbina, conhecida como curva colina, a qual está representada na Figura 1.4.




Figura 1.4 – Curva colina de uma turbina hidráulica. Fonte: Itaipu

Nesta curva, para uma determinada queda líquida, o rendimento da turbina aumenta com a vazão turbinada, até atingir um rendimento máximo. Após este ponto, acréscimos adicionais na vazão turbinada provocam o efeito contrário diminuindo o rendimento. Nas proximidades do ponto de maior rendimento obtém-se também o ponto de maior produtibilidade. A produtibilidade é a relação dada entre a potência produzida e a vazão turbinada, expressa em [MW/m³/s], sendo um excelente indicador de aproveitamento da água; pois quanto maior seu valor, maior a potência produzida com a mesma vazão turbinada.

O ponto ótimo de operação para uma determinada queda pode ser obtido da curva colina. Porém, diante da dificuldade prática de operar neste ponto, principalmente porque a queda é uma consequência da operação e não um valor previamente escolhido, Itaipu utiliza o conceito de faixas ótimas de operação, abordado em Andrade, Sanabria e Fernandez (2018), que pode ser observado na Figura 1.8. É definido um conjunto de faixas de eficiência, considerando as perdas percentuais em relação à produtibilidade máxima para uma determinada queda bruta. Por exemplo, cada ponto vermelho na Figura 1.5 representa um ponto de operação de uma

unidade geradora em um determinado horário ao longo do dia (Andrade, Sanabria e Fernandez, 2018).




Figura 1.5 – Curva das faixas de eficiência das unidades geradoras de Itaipu

Em um cenário de afluência desfavorável é necessário otimizar o consumo de água. Portanto, a programação diária busca operar as unidades geradoras dentro da faixa de menor perda (1%), ou seja, dentro da faixa ótima de operação. Este objetivo é atingido determinando o número ideal de unidades geradoras para cada patamar de geração do setor, de modo que o ponto de operação de cada unidade geradora permaneça o maior tempo possível dentro da faixa ótima.

Um exemplo pode ser observado na Figura 1.6, que representa um dia no qual foi programado um plano de despacho ótimo, de forma que o ponto de operação das unidades geradoras deveria permanecer 65% do dia dentro da faixa ótima, resultando em uma produtividade média diária de $1,080[\text{MW}/\text{m}^3/\text{s}]$. Cada ponto representa o patamar de potência das unidades geradoras despachadas, com o ponto vermelho indicando que a unidade está fora da faixa ótima e o ponto azul indicando que a unidade está dentro da faixa ótima.

No entanto, variações não programadas na geração da central hidrelétrica podem comprometer o plano ótimo de despacho, causando um desperdício de energia, representado pela água que poderia ter sido armazenada no reservatório.




Figura 1.6 – Plano de despacho ótimo programado

A Figura 1.7 mostra o impacto dos desvios do intercâmbio entre Itaipu e ANDE no plano de despacho ótimo, tendo como referência o dia apresentado na Figura 1.6. Neste dia houve um desvio médio de 31,55% na programação do intercâmbio. Este desvio, associado a ausência do redespacho do número de unidades geradoras para readequação ao novo cenário de produção, resultou em redução no ponto de operação das unidades geradoras e, consequentemente, em uma diminuição no tempo de permanência das unidades dentro da faixa ótima de 65% para 50% do dia. Este fato ocasionou uma redução na produtividade média diária de 1,080[MW/m³/s] para 1,074[MW/m³/s].




Figura 1.7 – Plano de despacho ótimo realizado

Em virtude destas características, a previsão de carga assume um papel muito importante neste processo, pois variações expressivas ocorridas em tempo real podem resultar em um menor aproveitamento dos recursos energéticos disponíveis, dificuldades adicionais para o controle do nível jusante e, até mesmo, afetar a segurança da operação dos sistemas interligados.

Desta forma, para mitigar as consequências negativas dos desvios da previsão de intercâmbio, este trabalho apresenta como objetivo a análise de viabilidade de aplicação de um modelo estatístico de previsão de carga de curtíssimo prazo no planejamento da operação hidroenergética de Itaipu, baseado nos conceitos de séries temporais estocásticas, descritos por Morettin e Toloí, 2006, com a finalidade de auxiliar a equipe de operação de sistemas elétricos na tomada de decisões em tempo real, quando o programa apresenta desvios significativos.

É importante destacar o aumento da participação da demanda do Sistema Elétrico do Paraguai na geração do setor de 50Hz de Itaipu, atingindo um patamar superior a 25% no ano a partir de 2017. Com o aumento recorrente desta participação, a ocorrência de desvios pode resultar em diferenças significativas no montante de geração.

O modelo de previsão adotado atualmente para o intercâmbio entre Itaipu e ANDE é baseado em um método heurístico de regressão linear que utiliza dados de temperatura e intercâmbio observados, bem como o conceito de padrões das curvas de demanda, considerando ciclos semanais típicos do comportamento da carga de um sistema elétrico, como descreve Martín & Acera (2005).

Como pode ser visto na Figura 1.8, o método atual apresenta uma performance adequada em aproximadamente 70% dos casos, nos quais os desvios permaneceram dentro da faixa de até 10%. Assim, é importante destacar que o trabalho não tem a pretensão de propor um método para substituição formal e em tempo integral do método utilizado atualmente pela ANDE. A motivação surgiu da necessidade de tratar os casos com desvios superiores a 10%, os quais correspondem a aproximadamente 30% dos casos.




Figura 1.8 – Histograma dos desvios do intercâmbio entre Itaipu e ANDE

1.1 Objetivos

O principal propósito deste trabalho é analisar a viabilidade de aplicação de um método de previsão a ser utilizado pela a equipe de tempo real da operação do sistema de Itaipu, para auxílio no controle dos níveis montante e jusante, bem como no cumprimento do plano de despacho ótimo de unidades geradoras em um cenário de desvios consideráveis na programação oficial do intercâmbio entre Itaipu e ANDE.

Na medida em que uma melhor previsão do intercâmbio entre Itaipu e ANDE, resulta em projeções mais precisas nos níveis montante e jusante de Itaipu e fornece a equipe de execução da operação tempo hábil suficiente para analisar uma eventual necessidade de readequação do número ótimo de unidades.

Desta forma, definem-se os seguintes objetivos:

1.1.1 Objetivo Geral

O objetivo principal deste trabalho é identificar um método de previsão de carga de curtíssimo prazo do intercâmbio entre Itaipu e ANDE, para ser disponibilizado à equipe de execução da operação, em cenários de desvios significativos com relação ao intercâmbio adotado durante a fase de planejamento da operação.

1.1.2 Objetivos Específicos

- Identificar os métodos de previsão de curtíssimo prazo, focando nas características de utilização e no tipo de dados adotados;
- Executar a coleta e o pré-processamento dos dados de intercâmbio entre Itaipu e ANDE para identificar as características das séries temporais resultantes;
- Selecionar um método de previsão, considerando as características das séries temporais;
- Testar o método escolhido a partir de uma ferramenta de análise de previsão.
- Comparar os resultados obtidos com os dados de programação adotados no processo de planejamento de curtíssimo prazo.

1.2 Estrutura do Trabalho

O Capítulo 2 apresenta uma revisão bibliográfica com os conceitos básicos dos principais métodos pesquisados, com vantagens e desvantagens, considerando as características dos dados e do problema, bem como o objetivo e propósito a serem alcançados.

O Capítulo 3 relata o método de Box & Jenkins, utilizado neste trabalho para a solução dos desvios do intercâmbio entre Itaipu e ANDE, escolhido após análise de suas principais características e adequação com o problema apresentado.

No Capítulo 4 apresenta-se os principais resultados obtidos com a aplicação do método utilizado, comparando-os com a programação diária utilizada nos dias elegidos para análise dos resultados.

Finalmente, no Capítulo 5 tem-se as conclusões da análise dos resultados obtidos e a indicação para motivar trabalhos futuros.

Capítulo 2

Revisão Bibliográfica

Uma grande variedade de modelos, variando na complexidade da forma funcional e nos procedimentos de estimação, tem sido proposta para a melhoria da acurácia da previsão de carga. Dependendo das características das observações e do problema de previsão que se deseja abordar, um método apresenta vantagens e desvantagens em relação a outro (Alferes & Nazeeruddin, 2002).

Desta forma, faz-se necessário a realização de uma pesquisa dos principais métodos utilizados para a previsão de carga, identificando o método que mais se adequa às características da série temporal formada pelo intercâmbio entre Itaipu e ANDE e ao problema a ser abordado.

2.1 Métodos de Previsão de Carga

De forma geral, pode-se agrupar os métodos de previsão de carga em basicamente quatro categorias, baseadas em seus horizontes de previsão, quais sejam, previsão de carga de curtíssimo prazo, de curto prazo, de médio prazo e, finalmente, previsão de carga de longo prazo, com seus respectivos horizontes de separação sendo de um dia, duas semanas e três anos, conforme representados na Figura 2.1 (Hong e Fan, 2016).



Figura 2.1 – Categorias das previsões de carga de acordo com o horizonte de previsão.
Fonte: Adaptado de Hong, T. & Fan, S., (2016)

Os métodos de previsão de carga são classificados em dois grupos. Um grupo que utiliza as técnicas estatísticas, no qual destacam-se os modelos de *regressão múltipla*, *semi-paramétricos*, *modelos autorregressivos e média móvel (ARMA)* e *amortecimento exponencial* e um grupo que utiliza as técnicas de inteligência artificial, no qual destacam-se os modelos de *redes neurais(ANN)* e *vetor de máquinas de suporte(SVM)* (Hong e Fan, 2016).

A seguir serão apresentados os métodos que foram pesquisados, em função das características da série temporal de interesse e do problema de previsão que deseja-se resolver.

2.1.1 Regressão Linear Múltipla

O método de regressão múltipla, descrito na equação 2.1, obtém, a partir de uma determinada amostra de dados observados, uma função que estima uma variável dependente (z_t), assumindo que ela tem uma relação linear com algumas variáveis independentes (v_t), ou variáveis explicativas. O processo consiste em estimar os coeficientes do vetor a_t em (2.1) de tal modo que os desvios (ε_t) entre os valores observados e estimados sejam mínimos. Uma das formas mais usadas para obter os coeficientes é a aplicação do *método dos mínimos quadrados* que objetiva minimizar a soma dos quadrados dos erros observados (Martin & Acera, 2005).

$$z_t = v_t a_t + \varepsilon_t \quad (2.1)$$

Modelos de regressão múltipla têm sido utilizados na literatura tanto em previsões de curto prazo, como em previsões de longo prazo. Usualmente a carga é usada como uma variável dependente, enquanto variáveis que influenciam o consumo de energia elétrica, tais como temperatura, umidade do ar, tipo de dia, são consideradas como variáveis independentes (Hong & Fan, 2016).

Al-Garni, Zubair & Nizami (1994) utilizaram a técnica de regressão linear para modelar o consumo mensal de energia elétrica da região da Arábia Saudita Oriental como uma função de dados meteorológicos, da radiação solar e da população, utilizando dados de um período de cinco anos de observação. O modelo de regressão obtido foi comparado com os valores observados, apresentando resíduos em uma faixa de -12% a 18%.

Rothe, J. Wadhwani & S. Wadhwani, (2009) adotaram o método de regressão múltipla para a demanda da próxima hora de uma determinada região da Índia, utilizando como variáveis independentes informações de demanda, temperatura, vento e nebulosidade observadas na hora corrente, bem como nas duas últimas horas, formando uma regressão com doze parâmetros. Os resultados apresentaram um erro médio da ordem de 7%.

Ao considerar modelos de regressão linear para a previsão de demanda elétrica, um equívoco típico é que tais modelos não são adequados para modelar a não-linearidade da relação entre a carga e as variáveis meteorológicas. De fato, uma das vantagens desta técnica é justamente a possibilidade de inserir no modelo variáveis que influenciam de forma relevante no comportamento da carga, tais como temperatura, umidade do ar, velocidade do vento, dentre outras. Na verdade, a característica linear no modelo refere-se às equações lineares que são adotadas para a estimar os melhores coeficientes do modelo (Hong e Fan, 2016).

2.1.2 Amortecimento Exponencial

O método de Amortecimento Exponencial considera que cada observação de uma série temporal é função das anteriores, sendo que as mais antigas (l_{t-1}) possuem um peso exponencialmente menor. O conceito deste modelo pressupõe que as últimas observações (l_t) de uma série terão informações mais atualizadas sobre a demanda e, conseqüentemente, mais

importância na previsão futura ($\hat{l}_{t+1}$), sendo expresso na equação 2.2 (Moghram & Rahman, 1989):

$$\hat{l}_{t+1} = \alpha l_t + (1 - \alpha)l_{t-1} \quad (2.2)$$

O método é denominado exponencial, pois os pesos ($\alpha \in [0,1]$) ligados às observações diminuem exponencialmente à medida que retrocedemos no tempo. A grande dificuldade do método é definir um peso adequado, pois um peso muito elevado pode fazer com que a previsão fique extremamente sensível às variações aleatórias das demandas, ao passo que um peso muito baixo tornará o modelo muito estável, resistente às tendências presentes na série. Uma das formas é definir um peso que minimize o *erro quadrático médio* (EQM), conforme equação 2.3, que é uma estimativa da variância do erro de previsão (Weron, R., 2006):

$$EQM = \frac{1}{n} \sum_{t=1}^n (l_t - \hat{l}_t)^2 \quad (2.3)$$

A robustez e a precisão da suavização exponencial levaram à sua ampla utilização em diversas aplicações relacionadas a previsão de demanda.

Christiaanse (1971) aplicou o método de amortecimento exponencial para obter um modelo de previsão de carga em tempo real. O modelo foi obtido através de simulações de uma série representando dados de demanda horários de dois anos (1966-67), com um horizonte de vinte e quatro horas de previsão. O processo de obtenção dos parâmetros é executado a cada hora, permitindo que o modelo se adapte a partir das novas observações. Os resultados apresentaram um erro mínimo médio de 2% para a hora seguinte e um erro máximo de 4% para o horizonte de 24 horas.

Apesar do sucesso em alguns trabalhos acadêmicos, a técnica de amortecimento exponencial é raramente utilizada no mundo real para a previsão da demanda de energia elétrica, devido à impossibilidade de utilização de variáveis exógenas no modelo. Desta forma, como a demanda tem relação direta com as características climáticas da região, o modelo apresenta desvantagem em aplicações onde são observadas volatilidades nas condições climáticas (Hong e Fan, 2016).

2.1.3 Séries Temporais Estocásticas

Os métodos de previsão que utilizam o conceito das *séries temporais estocásticas* detectam e exploram o pressuposto de que os próprios dados observados de uma série apresentam uma estrutura interna, como autocorrelação, tendência, ou variação sazonal. Este método tem sido usado por décadas nos campos da economia, processamento digital de sinais, assim como na previsão do consumo de energia elétrica (Weron, 2006).

Na década de 1970, Box & Jenkins (1976) introduziram um modelo que contém uma parcela autorregressiva (AR), uma parcela de médias móveis (MA) e inclui, explicitamente, a

diferenciação (I) da série, pois como o referido método é aplicado em série estacionárias, há necessidade de aplicar previamente sucessivas diferenciações até torna-la estacionária.

Especificamente, conforme descrito em Weron (2006), o Modelo Autorregressivo Integrado de Médias Móveis (ARIMA), ou modelo Box&Jenkins, possui três tipos de parâmetros, quais sejam, os parâmetros autorregressivos ($\phi_1 \dots \phi_p$), o número de diferenciações (d) e, finalmente, os parâmetros da média móvel ($\theta_1 \dots \theta_q$).

Pela notação de Box & Jenkins (1976), uma série que necessita ser diferenciada d vezes e, em seguida, apresenta as ordens p e q para as parcelas AR e MA, respectivamente, é denotada por ARIMA (p,d,q).

Adicionalmente, as generalizações de modelos ARIMA para processos com componentes sazonais são denominados modelos SARIMA. A notação para o modelo ARIMA sazonal é ARIMA (p,d,q)x(P,D,Q) s , na qual o termo (p,d,q) corresponde a ordem da componente não sazonal e o termo (P,D,Q) define a ordem da componente sazonal. Por último, o termo s define o número de observações da série inserida no padrão da sazonalidade, ou seja, sete para séries diárias com sazonalidade semanal, 24 para séries horárias com periodicidade diária.

Chen, Wang e Huang (1995), desenvolveram um modelo ARMA adaptativo para previsão de carga de curto prazo de um sistema elétrico de potência, com horizonte de uma hora a uma semana a frente. Esta abordagem deriva os coeficientes de erro de aprendizagem em virtude da teoria do erro quadrático médio mínimo e na sequência atualiza as previsões com base nos erros de previsão de um passo à frente e nos coeficientes. Devido à sua capacidade adaptativa, a proposta pode lidar com qualquer condição incomum do sistema. O modelo foi testado com dados de demanda de 42 dias, provenientes de uma subestação da companhia de energia elétrica de Taiwan, sendo as séries classificadas em dois tipos, quais sejam: dias de semana e finais de semana, bem como feriados. Para o modelo de previsão dos dias de semana, os resultados apresentaram um erro de 1,61% para o horizonte de uma hora à frente, e um erro médio de 1,27% para o horizonte de 24 horas.

De acordo com Zhang (2003), uma limitação dos modelos ARIMA é o fato deste ser linear, sendo que muitas séries reais apresentam características não lineares que não podem ser aproximadas por relações lineares de forma eficiente. No entanto, segundo Martin e Acera (2005), este modelo apresenta uma base estatística muito sólida, permitindo, por exemplo, obter analiticamente intervalos de confiança, os quais contribuem muito para a assertividade na tomada de decisões em tempo real, considerando as incertezas envolvidas no processo de operação de uma usina hidrelétrica.

2.1.4 Redes Neurais Artificiais

As redes neurais artificiais (RNA) são sistemas paralelos distribuídos compostos por unidade de processamento, chamados de neurônios artificiais, que calculam determinadas funções matemáticas, lineares e não lineares. O funcionamento dessas redes é inspirado em uma

simplicação do sistema neural biológico, com capacidade de aprendizado, generalização, associação e abstração (Haykin, 2009).

Um neurônio artificial é apresentado na Figura 2.2 é composto por dois módulos de processamento. O primeiro módulo, denominado regra de propagação, executa uma soma ponderada das entradas x_i multiplicadas pelos pesos sinápticos associados a cada entrada w_i . O segundo módulo de processamento, denominado função de ativação, aplica uma função ao resultado da regra de propagação. O resultado da função de ativação é a saída y do neurônio artificial (Haykin, 2009).




Figura 2.2 – Neurônio Artificial.
Fonte: Haykin 2019

Uma das arquiteturas mais utilizadas de redes neurais artificiais é a rede *Multilayer Perceptron* – *MLP*, podendo ser aplicada em uma ampla gama de problemas, inclusive na previsão de carga (Moreno e Garcia, 2011).

A arquitetura de uma MLP é baseada em neurônios dispostos em camadas, com a comunicação ocorrendo por meios de sinapses com pesos. É formada por uma camada de entrada, uma camada de saída e uma ou mais camadas intermediárias, como mostra a Figura 2.3 (Haykin, 2001).

A rede é do tipo *feed-forward*, com o sinal de entrada X sendo combinado com os pesos sinápticos $W^{(i)}$ e então propagados pela rede. A saída de cada neurônio da camada de entrada e da(s) camada(s) intermediária(s) constituem a entrada das camadas subsequentes, até que seja gerada uma saída Y (Haykin, 2001).




Figura 2.3 – Arquitetura MLP de uma rede neural.

Fonte: Haykin 2001

Algoritmo de treinamento é o *back-propagation*, no qual um sinal de erro é calculado na saída da rede e então propagado no sentido reverso, camada a camada, de modo que o erro produzido pela rede fique abaixo de um limite pré-determinado (Haykin, 2001).

O. Barbosa (2014) aplicou a técnica para automatizar a previsão de demanda horária do Sistema Interconectado do Paraguai. A partir dos dados de intercâmbio dos anos de 2011 e 2012 foram geradas 24 séries temporais, correspondente a cada hora do dia. Cada série temporal deu origem a uma rede MLP, resultando em um modelo com um total de 24 redes MLP, uma para cada hora do dia. Segundo Barbosa (2014), o objetivo desta proposta é reduzir a quantidade de parâmetros da rede, quando comparada a uma única rede com 24 saídas. A camada de entrada de cada rede foi desenvolvida para receber informações como dados de demanda das cinco horas anteriores, da mesma hora da semana anterior, classificação do tipo do dia e, finalmente, informações das condições climáticas, tais como temperatura, umidade relativa do ar, velocidade do vento e precipitação. Os resultados apresentaram um MAPE de 1,35% com testes de validação utilizando 146 dias.

De acordo com Zhang, Patuwo e Hu (1998) e Almeida (2013) as grandes dificuldades relacionadas a utilização de redes neurais concentram-se na escolha da topologia da rede, a qual não segue uma teoria exata e acontece de forma empírica, bem como na interpretação dos conceitos assimilados pelas RNAs, pois estes são codificados em seus pesos, resultando em uma caixa preta.

2.1.5 Máquinas de Vetores de Suporte

As Máquinas de Vetores de Suporte (*SVM – Support Vector Machines*) são modelos de aprendizagem supervisionada com a associação de algoritmos de aprendizagem. Sua teoria foi inicialmente elaborada para a solução problemas de classificação, através da aplicação do conceito de hiperplano ótimo de separação, baseado na maximização da margem de separação (Burges, 1998).

As SVMs lidam com problemas não lineares mapeando o conjunto de treinamento de seu espaço original, referenciado como de entradas, para um novo espaço de maior dimensão,

denominado espaço de características. Este procedimento é descrito por Cover (1965), o qual afirma que seja $\Phi: X \rightarrow \mathcal{F}$ um mapeamento, em que X é o espaço de entrada e $\mathcal{F}$ denota o espaço de características, dado um conjunto de dados não linear no espaço de entrada, uma escolha apropriada de Φ faz com que X possa ser transformado em um espaço de características $\mathcal{F}$ com alta probabilidade dos dados serem linearmente separáveis, desde que a transformação seja não linear e que a dimensão do espaço de características seja suficientemente alta (Hearst *et al*, 1998).




Figura 2.4 (a) Conjunto de dados não linear; (b) Fronteira não linear no espaço de entradas; (c) Fronteira linear no espaço de características.

Fonte: K. R. Müller, 2001

Como forma de ilustrar a teoria, considere um conjunto de dados apresentado na Figura 2.4.a. Transformando os dados de $\mathcal{R}^2$ para $\mathcal{R}^3$ como mapeamento apresentado na equação (2.7), o conjunto de dados não linear em $\mathcal{R}^2$ torna-se linearmente separável em $\mathcal{R}^3$, como mostra a Figura 2.4.c.

$$\Phi(x) = \Phi(x_1, x_2) = (x_1^2, \sqrt{2} x_1 x_2, x_2^2) \quad (2.7)$$

Assim, é possível obter um hiperplano com a capacidade de separar estes dados, conforme apresenta a equação (2.8).

$$f(x) = w\Phi(x) + b = w_1 x_1^2 + w_2 \sqrt{2} x_1 x_2 + w_3 x_2^2 + b = 0 \quad (2.8)$$

Observa-se que a função apresentada, embora linear em $\mathcal{R}^3$, corresponde a uma fronteira não linear em $\mathcal{R}^2$, como indica a Figura 2.4.b.

Logo, mapeia-se inicialmente os dados para um espaço de maior dimensão utilizando Φ e aplica-se a SVM linear sobre este espaço. Assim, encontra-se o hiperplano com maior margem de separação, garantindo uma boa generalização.

O algoritmo SVM foi estendido para o caso de regressão, por Vapnik (1995), possibilitando estimar funções de valores reais, resultando no conceito *Support Vector Regression Machine* (SVRM), ou simplesmente *Support Vector Regression* (SVR).

Tian e Noore (2004) propõem um modelo baseado neste conceito para a previsão de carga com o horizonte de 24 horas da cidade de Berkeley (Califórnia), utilizando em um primeiro

momento, apenas os dados históricos da demanda e, em seguida, inserem algumas variáveis de entrada relacionadas como consumo de energia elétrica, como temperatura e umidade. Os resultados apresentaram um desvio médio da ordem de 5,1%, para o modelo tendo apenas os dados históricos como entrada e 5,4% para o modelo com a inserção dos dados de temperatura e umidade.

Martin e Acera (2005) argumentam que uma vantagem dos modelos baseados no conceito SVM reside na característica de dispersão do problema de otimização, resultando em uma maior eficiência na fase de estimação dos parâmetros do modelo. Por outro lado, as máquinas de vetores de suporte apresentam-se como uma técnica não adaptativa, podendo ser uma desvantagem, quando aplicada em séries nas quais as características variam lentamente com o tempo.

A partir da revisão bibliográfica, pode ser observado que existem diversos modelos de previsão de carga diferindo na complexidade da aplicação e nas características e necessidades dos dados de entrada do processo de previsão, cada um apresentando vantagens e desvantagens, dependendo da aplicabilidade sobre o problema de previsão que se deseja abordar.

Considerando como premissa básica a seleção de um método que apresente total independência com relação às variáveis explicativas, principalmente relacionadas com variáveis climáticas, limitou-se a análise aos métodos univariados. Esta decisão foi baseada no fato de que os dados de intercâmbio que formam a série de interesse permanecem armazenados e consolidados com absoluta confiabilidade. Este mesmo nível de confiabilidade não pode ser atribuído aos dados climáticos, pois muitas vezes estas informações apresentam falha em telemetria, podendo impactar de forma negativa na eficiência do método de previsão. Como exemplo, a Figura 2.5 mostra o comportamento da temperatura de Assunção/PY, a qual poderia ser utilizada como variável exógena para explicar o comportamento do intercâmbio entre Itaipu e ANDE. Como pode ser observado, os dados apresentam inúmeras falhas, o que demandaria um trabalho adicional para tentar estimar os dados faltantes.




Figura 2.5 – Dados da temperatura de Assunção/PY.

Assim, dentre os métodos univariados estudados neste trabalho, optou-se pelo método baseado no conceito de obtenção de modelos autorregressivos integrado de médias móveis – ARIMA pois, além da premissa supracitada, este método apresenta uma variante que explora as características da sazonalidade cíclica das séries temporais, muito comum nos dados de consumo de energia elétrica, resultando na obtenção de modelos SARIMA.

Todo o processo de obtenção de modelos SARIMA a partir de séries temporais é baseado no conceito de Box & Jenkins e será explicado com mais detalhe no capítulo seguinte.

Capítulo 3

Materiais e Métodos

Neste capítulo é apresentado com maior detalhamento o método utilizado neste estudo, assim como os procedimentos adotados para a obtenção dos resultados.

Primeiramente abordam-se os conceitos elementares sobre as séries temporais e o processo de obtenção de modelos baseados na teoria Box&Jenkins. Em seguida, são descritos os passos para obtenção dos modelos, utilizando o recurso da previsão automática.

3.1 Séries Temporais

Uma série temporal discreta é qualquer conjunto de observações ordenada no tempo, obtida através da amostragem de uma série temporal contínua em intervalos de tempo iguais (Δt). Desta forma, para analisar uma série temporal, faz-se necessário amostrá-la em intervalos de tempo regulares e fixos como, por exemplo, em intervalos de uma hora (Morettin e Toloi 2006).

Um dos enfoques empregados na análise de séries temporais é realizado no domínio do tempo, tendo como propósitos a investigação do mecanismo gerador da série, a realização de previsões de valores futuros e a descrição do comportamento, mais precisamente na identificação de eventuais tendências, ciclos e variações sazonais. Para este enfoque propõe-se a adoção de modelos paramétricos como os modelos ARIMA, derivados com base na metodologia de Box&Jenkins. Independente da metodologia empregada, os modelos devem ser parcimoniosos, ou seja, com número de parâmetros reduzidos e não devem apresentar dificuldades às pessoas interessadas em utilizá-los (Morettin e Toloi 2006).

Uma das características de uma série temporal está relacionada à *estacionariedade*. Diz-se que uma série é estacionária quando ela se desenvolve no tempo de forma aleatória em torno de uma média constante, refletindo alguma forma de equilíbrio estável. Uma série pode ser não-estacionária por um período de longo prazo, mas também pode ser considerada estacionária dentro de um intervalo de curto, ou até mesmo de médio prazo.

A Figura 3.1 apresenta a série formada pelas observações horárias do intercâmbio entre Itaipu e ANDE para o período considerado no estudo, correspondendo a um intervalo de observações horárias de até um ano.




Figura 3.1 – Série original que representa o intercâmbio entre Itaipu e ANDE

Outra característica importante em uma série diz respeito ao aspecto de *sazonalidade*. Consideram-se sazonais as observações que ocorrem regularmente dentro de um determinado período de tempo. Assim, seja uma série temporal $z(t)$ apresentando sazonalidade. Então, z_t relaciona-se com z_{t-1} , z_{t-2} , ... e também com z_{t-S} , z_{t-2S} , com S sendo a periodicidade da sazonalidade cíclica, ou seja, para uma série que apresenta observações horárias e sazonalidade cíclica diária, tem-se que $S=24$.

A Figura 3.2 mostra que o intercâmbio entre Itaipu e ANDE apresenta uma sazonalidade cíclica muito bem definida para um período de uma semana, com a curva de carga dos dias úteis apresentando comportamento similar, assim como a curva de carga dos sábados e dos domingos. A partir de então, o método baseado na obtenção de modelos SARIMA apresenta-se como uma opção adequada para a solução do problema.




Figura 3.2 – Gráfico da série original do intercâmbio entre Itaipu e ANDE destacando a sazonalidade

Assim, após uma análise elementar sobre os métodos estudados e apresentados na revisão bibliográfica, decidiu-se pela aplicação da metodologia baseada nos conceitos de Box & Jenkins pois, além das características da série supracitadas, trata-se de um método univariado, no qual os modelos são obtidos a partir da própria estrutura dos dados observados, sem a necessidade da utilização de informações adicionais, resultando em uma maior autonomia para o processo de previsão. A grande maioria dos outros métodos estudados em Hong e Fan (2016) e Alfares e Nazeerudin (2002) apresentam a necessidade de utilização de variáveis exógenas em seu processo de previsão, tais como a temperatura, e a indisponibilidade desta informação pode prejudicar o desempenho do método.

3.2 Metodologia Box e Jenkins

A metodologia das séries temporais estocásticas foi desenvolvida por Box & Jenkins (1970), sendo um dos métodos mais populares que já foram aplicados à previsão de carga no setor de energia elétrica. Basicamente, neste processo, a série de carga, $z(t)$, é modelada como a saída de um filtro linear que tem uma entrada de série aleatória, $a(t)$, geralmente chamada de ruído branco. Em outras palavras, o ruído branco $a(t)$ é transformado no processo $z(t)$ pelo filtro linear $\Psi(B)$, como mostrado na Figura 3.3.



Figura 3.3 – Filtro modelo ARIMA.

Fonte: Morettin e Toloi(2006)

A operação de filtragem linear consiste simplesmente de uma soma ponderada dos ruídos aleatórios, tal como indica a Equação 3.1:

$$z(t) = \mu + a(t) + \psi_1 a(t-1) + \psi_2 a(t-2) + \dots = \mu + \sum_{i=0}^{\infty} \psi_i a(t-i) \quad (3.1)$$

Dependendo das características do filtro linear, podem ser obtidos modelos como os que serão descritos a seguir.

3.2.1 Modelo Autorregressivo (AR)

No processo autorregressivo, o valor atual da série temporal $z(t)$ é expresso linearmente em termos de suas observações anteriores ($z(t-1)$, $z(t-2)$...) e um ruído aleatório $a(t)$. A ordem deste processo depende da observação anterior mais antiga em que $z(t)$ é regredida. Assim, para um processo autorregressivo de ordem p ($AR(p)$), este modelo pode ser escrito como:

$$z(t) = \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + a(t) \quad (3.2)$$

Introduzindo o operador defasador B que define $z(t-1)=Bz(t)$ e, consequentemente, fazendo $z(t-m)=B^m z(t-m)$, a equação 3.3 pode ser escrita na forma:

$$\phi(B)z(t) = a(t) \quad (3.3)$$

onde,

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots + \phi_p B^p \quad (3.4)$$

3.2.2 Modelo Média Móvel (MA)

No processo de média móvel, o valor atual da série temporal $z(t)$ é expresso linearmente em função das observações atuais e anteriores de uma série de ruído branco $[a(t), a(t-1), \dots]$. Esta série de ruído é construída a partir dos erros de previsão ou resíduos na medida que as observações do consumo se tornam disponíveis. A ordem deste processo depende da observação do ruído mais antigo ao qual $z(t)$ é regredido. Para uma média móvel de ordem q (isto é, $MA(q)$), este modelo pode ser escrito de acordo com equação 3.5

$$z(t) = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.5)$$

Analogamente, aplicando-se o operador defasador na série de ruído branco sobre a equação 3.5, resulta na equação 3.6.

$$z(t) = \theta(B)a(t) \quad (3.6)$$

onde,

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots + \theta_q B^q \quad (3.7)$$

3.2.3 Modelo Autorregressivo Média Móvel (ARMA)

O processo de média móvel autorregressivo é formado pela composição dos modelos autorregressivos e média móvel, no qual a observação atual da série temporal $z(t)$ é expresso linearmente em termos de suas observações em períodos anteriores ($z(t-1), z(t-2), \dots$), bem como em termos de observações atuais e anteriores dos erros das previsões $[a(t), a(t-1), \dots]$. A ordem do processo ARMA é selecionada pela observação anterior mais antiga da série e pela observação do erro de previsão mais antigo ao qual $z(t)$ está regredido. Para um processo de média móvel autorregressivo de ordem p e q (ou seja, $ARMA(p, q)$), o modelo é escrito como:

$$z(t) = \phi_1 z(t-1) + \phi_2 z(t-2) + \dots + \phi_p z(t-p) + a(t) - \theta_1 a(t-1) - \theta_2 a(t-2) - \dots - \theta_q a(t-q) \quad (3.8)$$

Aplicando-se o operador defasador na equação 3.8, tem-se a expressão 3.9.

$$\phi(B)z(t) = \theta(B)a(t) \quad (3.9)$$

3.2.4 Modelo Autorregressivo Média Móvel Integrado (ARIMA)

A série temporal definida anteriormente como AR, MA, ou como um processo ARMA apresenta uma característica estacionária. Isso significa que a média das séries de qualquer um desses processos e as covariâncias entre suas observações não mudam com o tempo. De acordo com Morettin e Toloi (2006), se o processo é considerado não estacionário, deve-se primeiramente aplicar a transformação da série para um processo estacionário. Para as séries temporais que não são estacionárias na média, isto pode ser realizado por um processo de diferenciação.

Seja o operador ∇ , então uma série temporal diferenciada da ordem 1 pode ser escrita da seguinte forma:

$$\nabla z(t) = z(t) - z(t - 1) \quad (3.10)$$

Introduzindo o operador defasador B , tem-se:

$$\nabla z(t) = (1 - B)z(t) \quad (3.11)$$

Consequentemente, uma série diferenciada de ordem d é definida como:

$$\nabla^d z(t) = (1 - B)^d z(t) \quad (3.12)$$

As séries estacionárias diferenciadas podem ser modeladas como AR, MA ou ARMA, resultando em processos de séries temporais com características ARI, IMA e ARIMA.

Para uma série que precisa ser diferenciada d vezes e tem ordens p e q para os componentes AR e MA (ARIMA (p, d, q)), o modelo pode ser escrito como:

$$\phi(B)\nabla^d z(t) = \theta(B)a(t) \quad (3.13)$$

3.2.5 Modelo Sazonal

Como resultado de ciclos diários, semanais, anuais ou outras, muitas séries temporais exibem comportamentos periódicos em resposta a um ou mais desses ciclos. Portanto, uma classe diferente de modelos que possuem essa propriedade é designada como processos sazonais. Séries temporais sazonais podem ser modeladas como um processo sazonal *AR*, *MA*, *ARMA* ou *ARIMA*, similar às séries temporais discutidas nas seções anteriores. Foi demonstrado que o modelo multiplicativo geral $(p, d, q) \times (P, D, Q)$ para um modelo de séries temporais pode ser escrito na forma:

$$\phi(B)\Phi(B^S)\nabla^d \nabla_S^D z(t) = \theta(B)\Theta(B^S)a(t) \quad (3.14)$$

Com ∇_S^D , $\Phi(B^S)$ e $\Theta(B^S)$ sendo definidos conforme segue:

$$\nabla_S^D = (z(t) - z(t - s))^D = (1 - B^S)^D z(t)$$

$$\Phi(B^S) = 1 - \Phi_1 B^S - \Phi_2 B^{2S} - \dots - \Phi_P B^{PS}$$

$$\Theta(B^S) = 1 - \Theta_1 B^S - \Theta_2 B^{2S} - \dots - \Theta_Q B^{QS}$$

O modelo expresso na equação 3.14 pode ser estendido para o caso onde tem-se duas sazonalidades definidas. Neste caso, a ordem do modelo é dada por $(p,d,q) \times (P,D,Q) \times (P',D',Q')$ e pode ser expressa da seguinte forma:

$$\emptyset(B)\Phi(B^S)\Phi'(B^{S'})\nabla^d\nabla_S^D\nabla_{S'}^{D'}z(t) = \theta(B)\Theta(B^S)\Theta'(B^{S'})a(t) \quad (3.15)$$

Onde as definições $\nabla_{S'}^{D'}$, $\Phi'(B^{S'})$ e $\Theta'(B^{S'})$ são expressas usando os segundos termos da série temporal sazonal:

$$\begin{aligned} \nabla_{S'}^{D'} &= (z(t) - z(t - s'))^{D'} = (1 - B^{S'})^{D'}z(t) \\ \Phi'(B^{S'}) &= 1 - \Phi'_1 B^{S'} - \Phi'_2 B^{2S'} - \dots - \Phi'_p B^{pS'} \\ \Theta'(B^{S'}) &= 1 - \Theta'_1 B^{S'} - \Theta'_2 B^{2S'} - \dots - \Theta'_q B^{qS'} \end{aligned} \quad (3.16)$$

Um exemplo de modelagem de séries temporais sazonais é o modelo para as observações do consumo horário de energia elétrica, o qual apresenta um ciclo diário. Tal modelo pode ser expresso usando o modelo da equação 3.16 com $s = 24$.

3.3 Estágios do Método Box e Jenkins

A estratégia para a construção de modelos ARIMA é formada a partir de um ciclo iterativo composto de três estágios, mostrados na Figura 3.4 no qual a escolha do modelo é baseada nas próprias observações.




Figura 3.4 – Fluxograma dos estágios de Box&Jenkins

- (a) fase de *identificação* de um modelo, utilizando a análise de autocorrelações, autocorrelações parciais e outros métodos baseados em funções penalizadoras;
- (b) fase de *estimação*, na qual os parâmetros do modelo identificado são estimados;
- (c) fase de *verificação* do modelo ajustado, para certificar que o modelo é adequado para o objetivo proposto.

No caso de o modelo não apresentar o desempenho adequado, o ciclo é repetido, retornando-se ao estágio de identificação.

Em geral, os modelos obtidos são parcimoniosos, contendo um número reduzido de parâmetros, sem comprometer a qualidade da previsão, quando comparados com demais modelos (Morettin e Toloi, 2006).

3.3.1 Fase de Identificação

A *identificação* é considerada a fase mais crítica de todo o processo. Uma das desvantagens de se adotar a análise de autocorrelações e autocorrelações parciais nesta etapa é o fato da necessidade de se ter uma certa experiência para ajuste do modelo. Para contornar esta dificuldade, geralmente aplicam-se as análises baseadas em funções penalizadoras. De qualquer forma, dependendo da análise adotada, pode-se obter modelos diferentes para a mesma série de observações (Morettin e Toloi, 2006).

Para a identificação de modelos, Akaike (1973) desenvolveu o critério de informação Akaike (*AIC*), que se origina da minimização da distância de Kullback-Leibler (K-L), baseada na *Função de Log-Verossimilhança (FLV)* em seu ponto máximo, acrescida de uma penalidade associada ao número de parâmetros do modelo, de acordo com equação 3.17.

$$AIC = -2 \sum_{i=1}^n \ln L(\hat{\mu}_i, z_i) + 2 \times (\text{números de parâmetros}) \quad (3.17)$$

Onde z_i é o i -ésimo valor da resposta e $\hat{\mu}_i$ é a estimativa de z_i , quando se ajusta um modelo de p parâmetros por meio da maximização da *FLV*. O termo que se adiciona à *FLV*, chamado de função de penalidade, tem a finalidade de corrigir um viés proveniente da comparação de modelos de diferentes números de parâmetros. Dentre vários modelos candidatos, deve ser escolhido aquele que apresentar o menor valor de *AIC*.

Considerando um caso de respostas com distribuição normal, a expressão do *AIC* pode ser simplificada, tendo a seguinte forma:

$$AIC = n \ln(\hat{\sigma}_p^2) + 2(p + 1) \quad (3.18)$$

onde $\hat{\sigma}_p^2$ é o estimador de máxima verossimilhança da variância do erro.

$$\hat{\sigma}_p^2 = \frac{\sum_{i=1}^n (z_i - \hat{\mu}_i)^2}{n} \quad (3.19)$$

Nota-se que o número de parâmetros da equação (3.18) é igual a $(p+1)$, já que o mesmo deve incluir os p parâmetros do modelo, mais a variância $\hat{\sigma}_p^2$.

O termo $2(p + 1)$ é denominado “termo penalizador” e aumenta quando o número de parâmetros aumenta, ao passo que a variância residual $\hat{\sigma}_{k,l}^2$ diminui. Desta forma, minimizar a equação 3.18 significa em identificar as ordens que equilibrem esse comportamento.

3.3.2 Fase de Estimação

Identificada ordem de um modelo ARIMA para uma série temporal precisa-se, a partir deste ponto, estimar os parâmetros do modelo. Assim, considera-se um modelo $ARIMA(p, q, d)$, a partir do qual seus parâmetros $p+q+1$ são inseridos no vetor $\xi = (\phi, \theta, \sigma_a^2)$, onde $\phi = (\phi_1, \dots, \phi_p)$ e $\theta = (\theta_1, \dots, \theta_q)$. Um dos métodos utilizados para estimar ξ é o método da máxima verossimilhança. Sejam as N observações $z_1, \dots, z_N$ de uma série e a função de verossimilhança $L(\xi|Z_1, \dots, Z_N)$ como uma função de ξ . Os estimadores de máxima verossimilhança (EMV) de ξ serão os valores que maximizam L ou $l = \log L$.

Para se determinar os EMV admite-se que o processo a_t é normal, ou seja, para cada t , $a_t \sim \mathcal{N}(0, \sigma_a^2)$. Nesta condição, os EMV serão aproximadamente os estimadores de mínimos quadrados (EMQ).

Tomando-se d diferenças para se atingir a estacionariedade, tem-se $n = N - d$ observações $W_1, \dots, W_n$, de tal forma que $W_t = \nabla^d Z_t$. Desta forma, como o modelo $ARMA(p, q)$ resultante é estacionário e invertível, pode-se escrever:

$$a_t = \tilde{W}_t - \phi_1 \tilde{W}_{t-1} - \dots - \phi_p \tilde{W}_{t-p} + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} \quad (3.20)$$

Para obter os a_t utilizando a equação 3.20 faz-se necessário calcular os valores iniciais para os $\tilde{W}$'s e para os a 's. Esta etapa pode ser resolvida por utilizando um procedimento denominado “*backforecasting*”, no qual os valores iniciais são estimados da amostra de observação.

Neste procedimento, também conhecido como não-condicional, o logaritmo da função de verossimilhança é dado por:

$$\ell(\xi) = f(\eta) - n \ln(\sigma_a) - \frac{S(\eta)}{2\sigma_a^2} \quad (3.21)$$

onde,

$$\eta = [\phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q] \quad (3.22)$$

e

$$S(\eta) = S(\phi, \theta) = \sum_{t=-\infty}^n [a_t(\eta, W)]^2 \quad (3.23)$$

Sendo denominada *função soma de quadrados não-condicional*, com

$$a_t(\eta, W) = E(a_t|\eta, W)^2 \quad (3.24)$$

De acordo com Box, Jenkins e Reinsel (1994), para séries que apresentam n relativamente grandes, a função $\ell(\xi)$ é dominada por $\frac{S(\eta)}{2\sigma_a^2}$. Portanto, de acordo com a equação 3.21, maximizar $\ell(\xi)$, corresponde a minimizar $S(\eta)$. Desta forma, para calcular a expressão 3.23, considerando um dado η , deve-se calcular as esperanças condicionais expressas na equação 3.24. Em seguida aplica-se o procedimento conhecido como “*backforecasting*”, calculando $[W_{-j}]$, com $j=0, 1, 2, \dots$. Deste modo, cria-se valores para antes do início da série.

Ainda segundo Box, Jenkins e Reinsel (1994), o modelo $\emptyset(B)W_t = \theta(B)a_t$ é equivalente ao modelo $\emptyset(F)W_t = \theta(F)e_t$, onde F é o operador de translação ao futuro e $e_t \sim \mathcal{N}(0, \sigma_a^2)$ é também um ruído branco. A expressão $\emptyset(F)W_t = \theta(F)e_t$ é conhecida como forma “backward” do processo e W_t é expressa em termos dos valores futuros de W_t e e_t .

3.3.3 Fase de Verificação

A partir de um modelo ajustado faz-se necessário verificar se o mesmo corresponde aos dados da série, ou deve-se reiniciar o processo iterativo na busca de um modelo de melhor performance. Para esta função utiliza-se alguns testes de diagnósticos baseados, em geral, nas autocorrelações estimadas dos resíduos.

Seja $\eta = [\hat{\theta}_1, \dots, \hat{\theta}_p, \hat{\theta}_1, \dots, \hat{\theta}_q]$ o vetor com os parâmetros estimados para um modelo ARIMA(p,q,d). Os resíduos estimados $\hat{a}_t$ podem ser obtidos por:

$$\hat{a}_t = \hat{\theta}^{-1}(B) \hat{\emptyset}(B)W_t \quad (3.25)$$

Assim, se o modelo obtido é adequado para representar o processo gerador da série, os resíduos estimados $\hat{a}_t$ tendem para um *ruído branco* a_t de média nula, sendo não correlacionados. Neste caso, a estatística abaixo,

$$Q(K) = n(n+2) \sum_{j=1}^K \frac{\hat{r}_j^2}{(n-j)} \quad (3.26)$$

Onde $\hat{r}_j$ representa as autocorrelações dos resíduos, apresentará uma distribuição χ^2 com $K-p-q$ graus de liberdade. Lembrando que a hipótese de *ruído branco* para os resíduos é rejeitada para valores grandes de $Q(K)$. Logo, Box e Pierce (1970) afirmam que, em geral, basta utilizar até as quinze primeiras $\hat{r}_j$.

3.4 Previsão Automática de Modelos ARIMA

A adoção da previsão automática parte da premissa de que um operador de sistema não teria o conhecimento, experiência e tempo suficiente para obter os modelos de previsão utilizando como base as funções de autocorrelações (*fac*) e autocorrelações parciais (*facp*). A obtenção e aplicação de modelos diferentes em cada turno de operação apresenta a vantagem da utilização de observações mais recentes para compor o processo de previsão.

Com o propósito de obter os modelos de previsão para as séries que representam o intercâmbio entre Itaipu e ANDE, foi adotada uma ferramenta de análise estatística, a qual possui uma função com capacidade de determinar modelos ARIMA de forma automática para serem utilizados na previsão da série.

Assim seja uma série z_t que segue um modelo ARIMA(p,d,q) se:

$$D(z_t, d) = \beta X_t + v_t \quad (3.27)$$

$$v_t = \rho_1 v_{t-1} + \dots + \rho_p v_{t-p} + \theta_1 \epsilon_{t-1} + \dots + \theta_q \epsilon_{t-q} \quad (3.28)$$

Com a ferramenta de previsão automática de modelos ARIMA, as únicas decisões a serem tomadas pelo previsor estão relacionadas à transformação da variável independente, o nível de diferenciação e o número de termos AR e MA (ordens p e q).

Os modelos podem ser estimados com diferentes métodos, seguindo as seguintes etapas, independentemente do método escolhido:

1. Determinar eventuais transformações sobre a variável independente;
2. Selecionar o nível de diferenciação para a variável independente;
3. Selecionar a ordem dos termos ARMA.

Para determinar se é necessário aplicar o processo de diferenciação sobre a série, aplica-se um método que calcula duas regressões:

$$D(z_t)^2 = \alpha_1 + \beta_1 z_t \quad (3.29)$$

$$D\log(z_t)^2 = \alpha_2 + \beta_2 \log(z_t) \quad (3.30)$$

A partir de então, é realizada uma comparação aplicando-se o teste de hipótese t de β_1 e β_2 . Caso o teste sobre β_2 resulte menor do que sobre β_1 , aplica-se a transformação usando $\log$.

Para decidir sobre a aplicação de um nível de diferenciação apropriado sobre a variável independente, são realizados sucessivos testes da raiz unitária, baseados nos testes de estacionariedade descritos por Kwiatkowski, D., Phillips, P. & Schin, P. (KPSS). Primeiramente, o teste é realizado sobre os dados sem a diferenciação. Caso o teste rejeite a hipótese nula, os dados são diferenciados e o teste é aplicado novamente. O processo continua até o nível onde não há mais a rejeição da hipótese nula.

Para obter a ordem do modelo ARMA(p, q), o aplicativo utiliza o processo da seleção de modelos. Este processo determina qual modelo se ajusta melhor a um conjunto de observações e utiliza-o para a previsão.

O *critério de informação* é o recurso mais utilizado para a seleção de modelos ARMA. Para esta função, a ferramenta de análise suporta três tipos de critérios, quais sejam, *Akaike*, *Schwarz* e *Hannan-Quinn*. Cada um destes critérios é baseado na *log-verossimilhança* estimada do modelo, no número de parâmetros e no tamanho das observações.

Uma questão importante sobre a utilização de *critérios de informação* é que os modelos precisam ser estimados sobre o mesmo conjunto de observações e com a mesma escala, ou seja, em geral, não se pode avaliar os modelos com a variável dependente submetida a diferenciações e transformações.

Assim, o *critério de informação* para a seleção de modelos pode somente ser usado em modelos ARIMA para determinar o número dos termos do ARMA(p, q). Este processo é efetuado especificando o número máximo de coeficientes dos termos AR(p) e MA(q). Em seguida, estima-se todos os modelos, considerando todas as combinações possíveis envolvendo os termos AR e MA, respeitando-se o número máximo de coeficientes previamente definido. Finalmente, elabora-se uma relação apresentando um ranking dos modelos obtidos,

considerando o *critério de informação* adotado e define-se como o melhor modelo aquele que apresenta o menor valor para o critério escolhido.

3.5 Intervalo de Confiança

A utilização da estimação especificando um único valor não permite avaliar qual a magnitude do erro que poderia estar se cometendo, pois, a média de uma determinada amostra não fornece informações suficientes para concluir quão próxima a estimação está da média da população. Para cobrir esta deficiência surgiu a proposta de construir *intervalos de confiança*, os quais são baseados na distribuição amostral do estimador pontual (Bussab e Morettin, 2013).

Suponha que se queira estimar a média μ de uma população qualquer, utilizando a média $\bar{X}$ de uma amostra de tamanho n . Do *Teorema Central do Limite*,

$$e = (\bar{X} - \mu) \sim N(0, \sigma_{\bar{X}}^2) \quad (3.31)$$

$$\text{com } \text{Var}(\bar{X}) = \sigma_{\bar{X}}^2 = \sigma^2/n$$

Assim, pode-se determinar a probabilidade de se cometer erros de determinadas magnitudes. Por exemplo, para um intervalo de confiança de 95%, tem-se:

$$P(\bar{X} - 1,96\sigma_{\bar{X}} < \mu < \bar{X} + 1,96\sigma_{\bar{X}}) = 0,95 \quad (3.32)$$

Logo, a expressão (3.32) deve ser interpretada da seguinte forma: seja uma quantidade grande de intervalos da forma $]\bar{X} - 1,96\sigma_{\bar{X}}, \bar{X} + 1,96\sigma_{\bar{X}}[$, então 95% deles conteriam o parâmetro μ .

Para ilustrar o conceito, a Figura 3.5, que representa o intervalo de confiança (IC) para μ , com $\gamma = 0,95$ e σ^2 conhecido.




Figura 3.5 – Representação de um IC para μ , com $\gamma = 0,95$ e σ^2 conhecido.

Fonte: Bussab e Morettin, 2013

Escolhida uma amostra e encontrada sua média $\bar{x}_o$ e admitindo-se $\sigma_{\bar{x}}$ conhecido, pode-se construir o intervalo abaixo:

$$]\bar{x}_o - 1,96\sigma_{\bar{x}}, \bar{x}_o + 1,96\sigma_{\bar{x}}[\quad (3.33)$$

O intervalo de (3.33) pode ou não conter o parâmetro μ mas, pelo exposto acima, tem-se 95% de confiança de que esteja dentro do referido intervalo. Usualmente, utiliza-se níveis de 90%, 95%, ou até 99%.

3.6 Dados Utilizados

Uma série temporal formada pelas observações horárias do intercâmbio entre Itaipu e ANDE apresenta características que variam significativamente, dependendo do horário, das estações no ano e do dia da semana, como pode ser observado na Figura 3.6.




Figura 3.6 – Amostra da série original

Em virtude deste comportamento, decidiu-se efetuar um trabalho de pré-processamento da série original, classificando-a em três tipos. Tal classificação adotou o critério da sazonalidade diária, resultando em uma série que representa os dias úteis da semana, ou seja, de segunda-feira a sexta-feira, uma série que representa os sábados e, finalmente, uma série que representa os domingos. Uma amostra do processo de tratamento dos dados pode ser observada nas Figuras 3.7 a 3.9, as quais apresentam uma sazonalidade muito bem definida de 24 observações.




Figura 3.7 – Série intercâmbio entre Itaipu e ANDE para Sábados.




Figura 3.8 - Série intercâmbio entre Itaipu e ANDE para Domingos.




Figura 3.9 – Série intercâmbio entre Itaipu e ANDE para dias úteis.

Desta forma, para verificar a eficiência do método proposto foram utilizados três conjuntos de séries, cada um representando a característica típica de um dia da semana (dia útil, sábado e domingo). Por sua vez, cada conjunto contém quatro séries que representam os

horizontes que são considerados na previsão (24 horas, 18 horas, 12 horas e 6 horas), os quais representam o início de cada turno da operação em tempo real.

Para verificar os resultados do método para um dia útil, foi adotada uma série envolvendo os dias úteis dentro do período de 01/01/2017 a 12/06/2017, com o objetivo de obter modelos de previsão para o dia 13/06/2017 com horizontes de 24 horas, 18 horas, 12 horas e 6 horas.

A Tabela 3.1 apresenta as principais características desta série que é representada na Figura 3.10.

Tabela 3.1 – Características para a série dos dias úteis

Num. Observações	Mínimo	Máximo	Média	Desvio Padrão
2.784	764MW	2.463MW	1.543MW	341MW




Figura 3.10 – Série completa do intercâmbio entre Itaipu e ANDE para o dia útil.

Analogamente, para verificar os resultados do método para um dia típico de sábado, foi adotada uma série envolvendo apenas sábados dentro do período de 01/01/2017 a 16/09/2017, com o objetivo de obter modelos de previsão para todos os horizontes definidos dentro do dia 23/09/2017.

A Tabela 3.2 apresenta as principais características da série para o dia típico de Sábado que é representada na Figura 3.11.

Tabela 3.2 – Características para a série dos dias de Sábado

Num. Observações	Mínimo	Máximo	Média	Desvio Padrão
888	845MW	2.177MW	1.440MW	290MW




Figura 3.11 – Série completa do intercâmbio entre Itaipu e ANDE para sábado.

Finalmente, para verificar os resultados do método para um dia típico de domingo, foi adotada uma série envolvendo apenas domingos dentro do período de 01/01/2017 a 30/07/2017, com o objetivo de obter modelos de previsão para todos os horizontes definidos dentro do dia 06/08/2017.

A Tabela 3.3 apresenta as principais características da série para o dia típico de Sábado que é representada na Figura 3.12.

Tabela 3.3 – Características para a série dos dias de Domingo

Num. Observações	Mínimo	Máximo	Média	Desvio Padrão
720	753MW	2.052MW	1.260MW	277MW




Figura 3.12 – Série completa do intercâmbio entre Itaipu e ANDE para domingo.

Observando-se as Figuras 3.10, 3.11 e 3.12, nota-se uma componente sazonal muito bem definida, corroborando a decisão de considerar termos sazonais nos modelos.

Capítulo 4

Testes e Resultados

Com o intuito de verificar a eficiência da proposta, foram realizadas simulações utilizando o recurso de previsão automática de uma ferramenta de análise estatística, considerando dias nos quais o programa do intercâmbio entre Itaipu e ANDE apresentou desvio significativo. Foram elegidos três dias que representam as séries dos dias úteis, os sábados e domingos, indicadas no item 3.5. Cada série utilizada nas simulações é obtida a partir do primeiro ciclo de observações registradas no ano até o ciclo que antecede o dia que se deseja simular. Os horizontes das simulações foram definidos para 6 horas, 12 horas, 18 horas e 24 horas, levando em consideração o início e duração dos turnos de operação da Itaipu e o tempo hábil para a tomada de decisões.

Para obter modelos relativamente parcimoniosos, limitou-se a ordem dos termos *AR* e *MA* em ‘5’, a sazonalidade foi limitada em ‘1’ e a possibilidade de diferenciação (termo *I*) limitada na ordem ‘1’.

Os modelos obtidos foram comparados com o programa do intercâmbio entre Itaipu e ANDE definido para a data em questão. Para mensurar a eficiência dos modelos obtidos e compará-los com os dados do intercâmbio programado, fez-se o uso do *M.A.P.E* (Mean Absolute Percentage Error) e do máximo *A.P.E.max* (maximum Absolute Percentage Error), largamente difundido e utilizado para a comparação de métodos de previsão, sendo definidos a seguir:

$$MAPE = \frac{100\%}{n} \sum_{n=1}^n \left| \frac{z_t - \hat{z}_t}{z_t} \right| \quad (4.1)$$

$$APEmax = \max \left(100\% \left| \frac{z_t - \hat{z}_t}{z_t} \right| \right) \text{ com } t = 1 \dots n \quad (4.2)$$

onde,

z_t : observação atual no tempo t

$\hat{z}_t$: previsão no tempo t

n : número de observações no horizonte de previsão

As Tabelas 4.1 a 4.4 apresentam os resultados obtidos com os MAPE e APEmax para todos os dias observados, comparando-os com o método atual para os intercâmbios programados e os modelos propostos pelo método adotado neste trabalho.

Tabela 4.1 – Modelos para o horizonte de 24 horas

	MAPE		APEmax				MODELO SARIMA
DIA	ATUAL	PROP.	ATUAL		PROPOSTO		
			%	[MW]	%	[MW]	
ÚTIL	16,78 %	5,54 %	28,85 %	370	10,04 %	126	(4,0,4)(1,0,1) ₂₄
SÁB	20,93 %	8,09 %	40,33 %	500	18,15 %	235	(4,0,4)(1,0,1) ₂₄
DOM	31,63 %	7,33 %	61,22 %	634	13,76 %	109	(3,0,5)(1,0,1) ₂₄

Tabela 4.2 – Modelos para o horizonte de 18 horas

MAPE			APEmax				MODELO SARIMA
DIA	ATUAL	PROP.	ATUAL		PROPOSTO		
			%	[MW]	%	[MW]	
ÚTIL	21,07 %	1,74 %	28,85 %	370	4,54 %	58	(4,0,4)(1,0,1) ₂₄
SÁB	21,21 %	5,13 %	40,33 %	500	13,44 %	167	(4,0,4)(1,0,1) ₂₄
DOM	38,43 %	3,65 %	61,22 %	634	10,80 %	178	(3,0,5)(1,0,1) ₂₄

Tabela 4.3 – Modelos para o horizonte de 12 horas

	MAPE		APEmax				MODELO SARIMA
DIA	ATUAL	PROP.	ATUAL		PROPOSTO		
			%	[MW]	%	[MW]	
ÚTIL	19,84 %	1,28 %	28,85 %	370	2,68 %	35	(5,0,4)(1,0,1) ₂₄
SÁB	27,40 %	9,60 %	40,33 %	500	17,28 %	214	(5,0,4)(1,0,1) ₂₄
DOM	37,81 %	4,64 %	61,22 %	634	10,41 %	171	(4,0,5)(1,0,1) ₂₄

Tabela 4.4 – Modelos para o horizonte de 6 horas

	MAPE		APEmax				MODELO SARIMA
DIA	ATUAL	PROP.	ATUAL		PROPOSTO		
			%	[MW]	%	[MW]	
ÚTIL	15,46 %	2,63 %	25,06 %	423	3,71 %	63	(5,0,4)(1,0,1) ₂₄
SÁB	29,68 %	4,64 %	40,33 %	500	11,25 %	139	(4,0,4)(1,0,1) ₂₄
DOM	26,10 %	6,07 %	37,21 %	511	8,44 %	139	(3,0,5)(1,0,1) ₂₄

Percebe-se que, em todos os casos, houve uma redução significativa no MAPE e APEmax, comparando o método proposto com a programação adotada no respectivo dia, a qual representa o método adotado atualmente. Considerando o MAPE, o método proposto conseguiu obter uma redução mínima de 11,24%, correspondendo a série que representa um dia útil, com horizonte de 24 horas e uma redução máxima de 34,78%, correspondendo a série que representa um Domingo, com horizonte de 18 horas. Analogamente, com relação ao APEmax, o método proposto conseguiu obter uma redução mínima de 18,81% ou 244MW, correspondendo a série que representa um dia útil, com horizonte de 24 horas e uma redução máxima de 50,81% ou 463MW, correspondendo a série que representa um Domingo, com horizonte de 12 horas.

Analisando-se o método proposto de forma isolada, observa-se que, para o MAPE, a melhor performance obtida foi de 1,28% para a série que representa o dia útil com horizonte de 12 horas, ao passo que a pior performance obtida foi de 9,60% para a série que representa um Sábado com horizonte de 12 horas. Analogamente, considerando o APEmax, a melhor performance obtida foi de 2,68% ou 35MW para a série que representa o dia útil com horizonte de 12 horas, ao passo que a pior performance obtida foi de 18,15% ou 235MW para a série que representa um Sábado com horizonte de 24 horas.

Sob o aspecto dos modelos sazonais obtidos para as séries simuladas, nota-se que o número de parâmetros obtidos pelos mesmos variou de 10 a 11, de acordo com os limites de entrada inseridos no processo de previsão automática. A componente AR atingiu a ordem máxima inserida (5) em 2 dos 12 cenários simulados, ao passo que a componente MA atingiu a ordem máxima em 5 dos 12 cenários simulados. Isto significa que o objetivo da parcimônia dos modelos foi plenamente atendido.

Outro aspecto importante que pode ser observado nos modelos obtidos, diz respeito ao parâmetro que identifica a necessidade de diferenciação (d) para tornar os modelos estacionários. Pelas Tabelas de 4.1 a 4.4, nota-se que este parâmetro é nulo, o que significa que não houve a necessidade de diferenciação das séries. Na verdade, este resultado já era esperado, pois a série original, formada pelas observações do intercâmbio entre Itaipu e ANDE, apresenta a característica de estacionariedade, como pode ser observado na seção 3.6. Este fato proporciona a possibilidade de representar os resultados por modelos Sazonais Autorregressivos de Médias Móveis, denotados por SARMA(p,q)(P,Q)s.

Uma outra forma de observar os resultados dos modelos obtidos, apresentados nas Tabelas 4.1 a 4.4, é utilizando a forma gráfica, apresentada a seguir para os cenários com horizonte de 24 horas, comparando-os com os dados observados e com o modelo adotado atualmente (PROG). A forma gráfica é importante para observar o comportamento da previsão ao longo de todo o horizonte de interesse.




Figura 4.1 – Intercâmbio entre Itaipu e ANDE observado, programado e o modelo proposto para um cenário de dia útil.




Figura 4.2 – Intercâmbio entre Itaipu e ANDE observado, programado e o modelo proposto para um cenário de dia de Sábado.




Figura 4.3 – Intercâmbio entre Itaipu e ANDE observado, programado e o modelo proposto para um cenário de dia de Domingo.

As Figuras 4.1 a 4.3 mostram que o método proposto (PROP24) é qualitativamente mais aderente em relação às observações do que o programa apresentado pela ANDE. Nota-se que o programa disponibilizado pela ANDE (PROG) apresenta boa aderência nas primeiras horas do dia, mais precisamente até às 5h. A partir deste horário, para os dois casos, o programa disponibilizado começa a apresentar desvios significativos, ao passo que o modelo proposto (PROP24) continua apresentando boa aderência. Este cenário, vivenciado pela equipe de operação do sistema, justifica a necessidade de realizar o processo de previsão do intercâmbio entre Itaipu e ANDE no curtíssimo prazo.

Para mensurar o impacto dos resultados obtidos pelos modelos propostos sobre o planejamento e operação hidroenergética de Itaipu, procedeu-se com as simulações aplicando os resultados da previsão sobre o mesmo cenário apresentado na Figura 1.3.

Sob o aspecto da atividade de controle do nível da régua R11, a Figura 4.4 mostra que a utilização dos resultados dos modelos propostos promove uma melhoria considerável nas projeções deste nível, na medida que a projeção com os dados do modelo proposto (PREV24) apresenta melhor aderência, quando comparada com a projeção observada (OBS). Para este caso em particular, o desvio máximo da projeção do nível da régua R11 com relação ao nível observado foi de 0,13[m], ao passo que o desvio máximo com os dados da programação original da ANDE foi de 0,71[m].




Figura 4.4 – Projeção do nível da régua R11 observada, programada e com o modelo proposto.

Da mesma forma, para cumprir o objetivo de busca da região de melhor produtividade, a adoção de uma previsão do intercâmbio entre Itaipu e ANDE com melhor acurácia, permite à equipe de tempo real promover um redespacho de unidades geradoras com o objetivo de mantê-las na região de maior rendimento, mesmo frente a desvios na programação.

Um exemplo pode ser observado na Figura 4.5, que mostra o plano de despacho para o dia 06/08/2017, onde os pontos em vermelho correspondem ao plano de despacho observado e os pontos em azul correspondem ao plano de despacho que poderia ter sido realizado em função de uma readequação no número de unidades. Durante o período de 2h às 10h, o intercâmbio entre Itaipu e ANDE apresentou-se inferior ao patamar programado. Assim, utilizando o modelo de previsão proposto, a equipe de execução da operação poderia decidir pelo desligamento de uma unidade geradora durante o período de 2h às 10h, o que conduziria o patamar de geração das unidades para a região da faixa ótima. Esta ação resultaria em uma redução da vazão média turbinada de 8.165 [m³/s] para 8.147 [m³/s], com o consequente aumento na produtividade média diária de 1,074[MW/m³/s] para 1,082[MW/m³/s].

A redução de 18 [m³/s] na vazão média diária corresponderia a uma energia de 467[MWh] que poderia ter sido armazenada no reservatório, suficiente para atender 80 mil habitantes por um dia. Considerando a média mensal do Preço da Liquidação das Diferenças (PLD) para o mês de agosto de 2017, a qual foi estabelecida em R\$ 505,95 (fonte: CCEE), a energia armazenada corresponderia a R\$ 236.542.




Figura 4.5 – Radequação no plano de despacho ótimo alterado

Como os resultados apresentados pelos modelos de previsão são estimativas da informação que se deseja prever, a construção de intervalos de confiança para os valores previstos, como um quantificador da confiabilidade da previsão, é um instrumento auxiliar na tomada de decisão da equipe de tempo real permitindo uma diminuição nos riscos no atendimento às restrições e diretrizes operativas, aumentando o nível de assertividade das ações de tempo real. Sendo assim, a título de exemplo, procedeu-se a obtenção do intervalo de confiança com 95% de confiabilidade, considerando um cenário de dia útil e um cenário de domingo com um horizonte de 24 horas.

Observa-se na Figura 4.6 que o programa disponibilizado pela ANDE no dia em questão apresentou patamares inferiores ao limite inferior do intervalo de confiança desde às 7h até às 20h. Outro fato importante a observar é que os dados observados (OBS) encontram-se majoritariamente dentro do intervalo de confiança.




Figura 4.6 – Intercâmbio entre Itaipu e ANDE observado, programado e do modelo proposto para um cenário de dia útil e intervalo confiança.

A Figura 4.7 mostra que o programa disponibilizado pela ANDE no dia em questão apresentou patamares superiores ao limite superior do intervalo de confiança desde às 7h até às 24h e que todos os dados observados (OBS) no período encontram-se dentro do intervalo de confiança calculado para PROP24.




Figura 4.7 – Intercâmbio entre Itaipu e ANDE observado, programado e para o modelo proposto para um cenário de Domingo e intervalo confiança.

Desta forma, o intervalo de confiança tem uma importância muito grande na tomada de decisão. Ou seja, dependendo do cenário apresentado para os operadores de sistemas no momento, estes podem ser conservadores nos riscos envolvidos e adotar medidas operativas, com base nos limites inferiores ou superiores do intervalo de confiança obtido.

Um exemplo pode ser observado na Figura 4.6, que apresenta um cenário no qual o intercâmbio entre Itaipu e ANDE mostrou-se superior ao patamar programado. Caso houvesse a necessidade do desligamento de uma de interligação, a análise da equipe de execução da operação seria baseada em um patamar inferior, podendo implicar em uma eventual sobrecarga nas linhas remanescentes. Com as informações do intervalo de confiança, a decisão da equipe de execução da operação seria, de uma forma mais conservadora, baseada nos limites superiores do intervalo de confiança, trazendo mais segurança à operação interligada.

Capítulo 5

Conclusão

Este trabalho apresentou uma análise de viabilidade de aplicação de um método clássico de previsão de carga de curtíssimo prazo, baseado nos conceitos de séries temporais de Box & Jenkins, para prever o intercâmbio de energia entre Itaipu e ANDE, com o objetivo principal de subsidiar a equipe de operação de Itaipu na tomada de decisões frente a desvios significativos na programação. A proposta apresentada aplica o método em três categorias diferentes de séries, classificadas de acordo com as características típicas dos dias da semana.

Foi realizada uma pesquisa bibliográfica dos principais métodos de previsão de carga utilizados ao longo do tempo, com destaque para os métodos baseados em *regressão linear múltipla*, *amortecimento exponencial*, *séries temporais estocásticas*, *redes neurais artificiais* e *máquina de vetores de suporte*, focando nos conceitos básicos de cada um e nas características do problema a ser solucionado.

A análise da série formada pelos dados horários do intercâmbio entre Itaipu e ANDE, possibilitou a identificação de três padrões de séries com características sazonais cíclicas que resultaram no pré-processamento da série formando uma série para representar os dias úteis, outra para representar o Sábado e, finalmente, uma série para representar o Domingo.

A partir do pré-processamento da série original, optou-se por um método baseado nas séries temporais estocásticas, neste trabalho em particular, o método SARIMA, da teoria de Box & Jenkins, devido ao fato das séries apresentarem um comportamento sazonal cíclico muito bem definido e por tratar-se de um método univariado, caracterizado pela necessidade de dispor apenas das observações da própria série para estimar os dados futuros. Esta característica fornece ao modelo a vantagem da simplicidade e autonomia, não dependendo de outras informações externas (variáveis exógenas), o que poderia prejudicar a performance em eventual falha na obtenção dos dados.

Desta forma, no caso deste trabalho, a proposta de viabilidade de utilização do método, consistiu na obtenção de modelos SARIMA simulando o início de cada turno de operação, com o horizonte variando de acordo o tempo restante para atingir o final do dia e considerando a característica da padronização do comportamento da carga em cada dia da semana.

Para verificar a eficiência da proposta foi adotado um aplicativo de análise estatística com o recurso de previsão automática de modelos SARIMA. As séries foram definidas, observando alguns dias nos quais a programação da ANDE apresentou desvios muito significativos. Definiu-se então três séries, um para cada dia típico da semana, com horizontes variando de acordo com os turnos de operação de Itaipu.

Os resultados obtidos apresentaram uma redução média de aproximadamente 80% no MAPE, quando se compara o método proposto com a programação que foi adotada nos dias que envolveram os testes. Além disso, verificou-se que todos os cenários testados apresentam redução significativa no MAPE, com uma redução mínima de 61% e uma redução máxima de 93%, demonstrando que o método proposto, baseado no conceito Box & Jenkins na obtenção de modelos SARIMA, é viável para ser aplicado na previsão de curto prazo do intercâmbio entre Itaipu e ANDE.

Constatou-se que a adoção do método proposto no processo de planejamento e execução da operação de tempo real de Itaipu, auxilia a equipe no controle do nível jusante da usina de, na medida em que resulta em uma melhoria na estimativa de projeção dos níveis de controle e suas restrições.

Verificou-se que o método proposto contribui para uma melhor otimização dos recursos energéticos de Itaipu, pois introduz a possibilidade da equipe de execução da operação promover uma alteração do número de unidades despachadas, readequando-o de acordo com uma nova previsão de geração, buscando a faixa ótima de operação com redução do consumo de água.

Outro ponto a destacar é que a adoção do intervalo de confiança pode ser muito importante no processo de tomada de decisões, pois dependendo das condições operativas observadas pela equipe da execução da operação, pode-se adotar os limites do intervalo para uma decisão mais conservadora, considerando toda a incerteza envolvida.

Diante dos benefícios que podem ser obtidos com a utilização do método proposto pela equipe de execução da operação, a próxima etapa do trabalho consiste no planejamento de um projeto de implantação do método dentro dos sistemas de apoio a tomada de decisão presentes na sala de controle.

Apesar dos resultados satisfatórios observados com o método proposto, ainda merece atenção o fato de que, em alguns cenários testados, o APEmax apresentou índices superiores a 10%, motivando a continuidade das pesquisas para redução destes índices. Sendo assim, como proposta de trabalhos futuros, propõe-se a adoção de variáveis exógenas, tais como a temperatura, para inserir no modelo o impacto das variações climáticas sobre o comportamento da curva de carga do intercâmbio entre Itaipu e ANDE. Como exemplo, seguindo a mesma linha de atuação deste trabalho, tem-se a possibilidade da utilização de modelos SARIMAX.

Referências Bibliográficas

- Akaike, H. (1973). *Maximum likelihood identification of Gaussian autoregressive moving average models*. *Biometrika*, 60: 255-265.
- Alfares, H. K. & M. Nazeeruddin, (2002). Electric load forecasting: literature survey and classification of methods, *International Journal of Systems Science* 33 (1): 21-34.
- Al-Garni, A. Z., Zubair, S. M. & Nizame, J. S. (1994). A regression model for electric energy consumption forecasting in eastern Saudi Arabia, *Energy*, 19 (10): 1043-1049.
- Almeida, V. A. (2013). *Previsão de Carga através de Modelos Neuro-Fuzzy*, Dissertação de Mestrado, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ.
- Andrade, R. J. & Sanabria R. E. O. (2017). Manual de Elaboração da Programação Energética de Itaipu, *Relatório Técnico*, Itaipu Binacional.
- Andrade, R. J., Sanabria, R. e Fernandez, R. (2018). Uma nova abordagem da produtividade para utilização em tempo real, *XV EDAO – Encontro para Debates de Assuntos de Operação*, 2018, Rio de Janeiro.
- Barbosa, O. A. (2014). Automatización de previsión de demanda horaria de potencia eléctrica en el Sistema Interconectado Nacional. *Revista Científica UCSA* 1 (1): 4-11.
- Box, G. E. P. & Jenkins, G. M. (ed 1) (1970). *Time Series Analysis: Forecasting and control*, Holden-Day, San Francisco.
- Box, G. E. P. and Pierce, D.A. (1970). Distribution of Residual Autocorrelations in Autoregressive-Integrated Moving Average Time Series Models. *Journal of the American Statistical Association*, 65:1509-1526.
- Box, G. E. P., Jenkins, G.M. & Reinsel, G.C. (ed. 3ª) (1994). *Time Series Analysis: Forecasting and Control*, Prentice Hall, Englewood Cliff, New Jersey.
- Burges, C. J. C. (1998). A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery* 2:121–167.
- Bussab, W. O. e Morettin, P. A. (ed. 8ª) (2013). *Estatística Básica*, Editora Saraiva, São Paulo.
- Chen, J. F., Wang, M. W. & Huang, C. M. (1995). Analysis of an adaptive time-series autoregressive moving-average (ARMA) model for short-term load forecasting, *Electric Power Systems Research* 34: 187-196.
- Christiaanse, W. R. (1971). Short-term load forecasting using general exponential smoothing, *IEEE Transactions on Power Apparatus and Systems* 90 (2): 900-911.
- Cover, T. M. (1965). Geometrical and Statistical Properties of Systems of Linear Inequalities with Applications in Pattern Recognition, *IEEE Transactions on Electronic Computers* 14 (3): 326-334.

- Fajardo, J. M. C. (2004). *Acordo Tripartite Itaipu-Corpus: Ponto de Inflexão entre a Disputa Geopolítica e a Política de Cooperação*, Dissertação de Mestrado, Universidade Federal do Rio Grande do Sul, Porto Alegre, RS.
- Gross, G. & Galiana, F. D. (1987). Short-Term Load Forecasting, *Proceedings of the IEEE*, 75 (12): 1558-1573.
- Haykin, S. (ed. 2ª) (2001). *Redes Neurais: Princípios e Prática*, Editora Bookman, Porto Alegre, RS.
- Haykin, S. (ed. 3ª) (2009). *Neural Networks and Learning Machines*, Printice Hall, 2009, Upper Saddle River, New Jersey.
- Hearst, M. A., Dumais, S. T., Platt, B. & Scholkopf, B. (1998). Support Vector Machine, *IEEE Intelligent systems and their applications*, 13: 18-28.
- Hong, T. & Fan, S., (2016). Probabilistic electric load forecasting: a tutorial review, *International Journal of Forecasting*, 32: 914-938.
- Kwiatkowski, D., Phillips, P.C.B., Schmidt, P. and Shin, Y. (1992) Testing the null hypothesis of stationarity against the alternative of a unit root, *Journal of Econometrics* 54: 159–178.
- Martín, M. & Acera, M. (ed.1ª) (2005). *Técnicas Neuronales y Estadísticas para la Predicción de Demanda Eléctrica*, Junta de Castilla y Leon.
- Moghran, I. & Rahmam, S. (1989). Analysis and evaluation of five short-term load forecasting techniques, *IEEE Transactions on Power Systems*, 4 (4): 1484-1491.
- Moreno, J. J. M., Pol, A. P. & P. M. Garcia (2011). Artificial neural networks applied to forecasting time series. *Psicothema*, 23 (2): 322-329.
- Morettin P. A., Bussab, W. de O. (ed. 6ª) (2010). *Estatística Básica*, Editora Saraiva.
- Morettin, P. A., Toloi, C. M. (ed 2) (2006). *Análise de Séries Temporais*, 2ª edição. Editora Blücher, São Paulo.
- Müller, K., Mika, S., Rätsch, G., Tsuda, K. & Schölkopf, B. (2001). An Introduction to Kernel-Based Learning Algorithms, *IEEE Transactions on Neural Networks*, 12 (2): 181-201.
- Rothe, J. P., Wadhwani, A. K. & S., Wadhwani, (2002). Short term load forecasting using multi parameter regression, *International Journal of Computer Science and Information Security*, 6 (2): 303-306.
- Shahidehpour, M., Yamin, H. & Li, Z. (ed 1) (2002). *Market Operations in Electric Power Systems*, Academic Press, San Diego, California.
- Tian, L. & Noore, A. (2004). A novel approach for short-term load forecasting using support vector machine, *International Journal of Neural Systems*, 14 (5): 329-335.
- Vapnik, V. N. (ed. 2) (1995). *The Nature of Statistical Learning Theory*, Springer, New York.
- Weron, R. (2006). *Modeling and Forecasting Electricity Loads and Prices*, John Wiley & Sons, LTDA, England.

- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model, *Neurocomputing*, 50: 159-175.
- Zhang, G. P., Patuwo, E. & Hu, M. Y. (1998). Forecasting with artificial neural networks: *The state of art*, *International Journal of Forecasting*, 14: 35-62.

Apêndice A

Parâmetros dos Modelos

Tabela A.1 – Parâmetros dos modelos.

	h	AR					MA					SAR	SMA	C	AIC
		p ₁	p ₂	p ₃	p ₄	p ₅	q ₁	q ₂	q ₃	q ₄	q ₅	P ₁	Q ₁		
Dia útil	24	1,2296	-0,2976	-0,3133	0,3320		-1,0190	0,0264	0,2949	-0,3024		0,9918	-0,7487	-0,2115	10,5135
	18	1,2241	-0,2933	-0,3134	0,3327		-1,0136	0,0232	0,2938	-0,3034		0,9918	-0,7493	-0,2044	10,5120
	12	1,0428	0,1896	-0,9441	0,7291	-0,0754	-0,8313	-0,4168	0,8079	-0,5597		0,9916	-0,7444	-0,2015	10,5910
	6	1,0441	0,1907	-0,9455	0,7282	-0,0752	-0,8327	-0,4183	0,8094	-0,5583		0,9917	-0,7449	-0,2043	10,5083
Sábado	24	-0,4508	0,6303	0,7456	-0,2418		0,5010	-0,7113	-0,9062	0,1166		0,9645	-0,7753	-0,3010	11,8930
	18	-0,4562	0,6253	0,7467	-0,2375		0,5043	-0,7096	-0,9079	0,1132		0,9664	-0,7843	-0,2795	11,8937
	12	-0,6332	-0,0490	0,5062	0,7753	-0,1328	0,6689	-0,0012	-0,6689	-0,9998		0,9681	-0,7845	-0,2696	11,8937
	6	-0,4567	0,6249	0,7469	-0,2373		0,5051	-0,7086	-0,9086	0,1121		0,9670	-0,7853	-0,2871	11,8813
Domingo	24	1,9012	-1,8955	0,9111			-1,8322	1,7664	-0,7837	-0,0792	-0,0312	0,9573	-0,6304	-0,5546	11,0496
	18	1,8997	-1,8943	0,9093			-1,8312	1,7249	-0,7828	-0,0784	-0,0325	0,9571	-0,6311	-0,6003	11,0493
	12	0,9201	-0,0213	-0,9572	0,9017		-0,8565	-0,1074	0,9612	-0,8749	-0,1224	0,9598	-0,6312	-0,5935	11,0416
	6	1,8993	-1,8936	0,9091			-1,8309	1,7241	-0,7818	-0,0798	-0,0316	0,9577	-0,6319	-0,5870	11,0323

Anexo A

MODELO DE PREVISÃO DE CARGA DE CURTO PRAZO

PARA O INTERCÂMBIO ENTRE ITAIPU E ANDE

ARTIGO APRESENTADO NO XVIII ERIAC

Foz do Iguaçu – PR

Maio de 2019



xviii eriac

Foz do Iguaçu, Brasil

**XVIII ERIAC
DÉCIMO OITAVO ENCONTRO
REGIONAL IBERO-AMERICANO DO CIGRE**

19 a 23 de maio de 2019



cigre

CE-NN

Comitê de Estudos C1 – Desenvolvimento de Sistemas Elétricos e Economia

MODELO DE PREVISÃO DE CARGA DE CURTO PRAZO PARA O INTERCÂMBIO ENTRE ITAIPU E ANDE

**E.M.C. FRANCO
UNIOESTE
Brasil**

**J.M. CORREA
UTFPR
Brasil**

**R.G. PIMENTA*
Itaipu Binacional
Brasil**

**S. BELLIDO
UTFPR
Brasil**

**T. HICKMANN
UTFPR
Brasil**

Resumo – Este trabalho apresenta a análise da viabilidade de aplicação de um modelo de previsão de carga de curto prazo para o intercâmbio entre Itaipu e ANDE, com o objetivo de auxiliar a equipe de operação de sistemas elétricos na tomada de decisões em tempo real quando da ocorrência de desvios significativos. Diante das características dos dados e do objetivo a ser atingido, utilizou-se a metodologia Box-Jenkins para o ajuste de modelos SARIMA gerados com um horizonte de 24 horas, comparando-os com a programação diária de operação. Os resultados apresentaram uma redução média no MAPE de 25% para 5%, atestando a eficiência do modelo para o problema apresentado.

Palavras chave: Previsão de Carga – Séries Temporais – ARIMA – SARIMA

1 INTRODUÇÃO

O desenvolvimento deste trabalho foi motivado pela necessidade de obtenção de um modelo de previsão de carga de curto prazo para auxiliar a equipe de operação em tempo real de Itaipu na tomada de decisões frente a eventuais desvios da programação do intercâmbio entre Itaipu e ANDE.

Itaipu é uma central hidrelétrica binacional que tem como sócios Eletrobras (Brasil) e ANDE (Paraguai). Foi construída a partir de 1974 e está localizada no Rio Paraná, na fronteira entre Brasil e Paraguai, próxima a cidade brasileira de Foz do Iguaçu e a cidade paraguaia de Hernandarias. Iniciou sua produção em 1984 e possui 20 unidades geradoras com potência de 700MW, totalizando uma potência instalada de 14.000MW, sendo a segunda maior hidrelétrica do mundo. Desde o início da operação, Itaipu já produziu mais de 2,6 bilhões de megawatts-hora e atualmente é responsável pelo suprimento de aproximadamente 15% da energia elétrica para o Brasil e de mais de 90% para o Paraguai.

A casa de força de Itaipu é dividida em dois setores, um operando na frequência de 50Hz e outro operando na frequência de 60Hz, cada um com 10 unidades geradoras. A energia gerada no setor de 60 Hz é transmitida para o Sistema Elétrico Brasileiro, utilizando o Sistema de 765kV de FURNAS e o Sistema de 525kV da Copel. A energia gerada no setor de 50Hz é escoada para o Sistema Elétrico Paraguaio, utilizando quatro linhas de 220kV e uma linha de 500kV, pertencentes a ANDE (Administración Nacional de Electricidad). O montante de energia que o Paraguai não utiliza é escoado para o Sistema Elétrico Brasileiro, a partir da subestação de Foz do Iguaçu no Paraná, utilizando o Sistema de Corrente Contínua de FURNAS 600kVCC Foz do Iguaçu-Ibiúna.

Os montantes de energia destinados a ambos os países são definidos durante o processo de elaboração do Programa Diário de Operação (PDO) de Itaipu, discretizados em intervalos de trinta minutos, no caso do intercâmbio entre Itaipu e Eletrobrás, ou de uma hora, no caso do intercâmbio entre Itaipu e ANDE. Neste ponto, é importante ressaltar que a geração total do setor de 50Hz é o resultado dos montantes de energia necessários para atender o intercâmbio com a ANDE e o intercâmbio entre Itaipu e Eletrobras transmitido pelo elo de corrente contínua, limitados à disponibilidade do referido setor desta usina. Devido a este fato, desvios significativos na previsão do intercâmbio com a ANDE pode comprometer o atendimento ao Sistema Elétrico Brasileiro, uma vez que um acréscimo não previsto no intercâmbio entre Itaipu e ANDE pode resultar em uma redução no intercâmbio entre Itaipu e Eletrobras, ou reduzir a eficiência da produção de energia da usina, pois uma redução não prevista no intercâmbio entre o Itaipu e ANDE pode ter como consequência uma disponibilidade de energia não utilizada [1].

Outro aspecto importante na operação de uma usina hidrelétrica está baseado no controle da vazão defluente, necessário para garantir a preservação do meio ambiente, a navegabilidade, a segurança da barragem e demais usos múltiplos da água. Um acordo firmado entre Argentina, Brasil e Paraguai, estabelece que a defluência proveniente da usina não pode provocar variações superiores a dois metros no nível situado na margem paraguaia do Rio Paraná, na confluência deste rio com o rio Iguaçu, em um intervalo de 24 horas [2]. Desta forma, variações não programadas na vazão defluente da usina de Itaipu pode comprometer o cumprimento do referido acordo, bem como dificultar o atendimento dos procedimentos de segurança da barragem quando o nível montante encontra-se próximo do limite máximo operativo.

Um aspecto não menos importante da previsão de carga está presente na determinação do plano ótimo de despacho de unidades geradoras, o qual, em uma central hidrelétrica, busca um ponto de operação para as unidades que resulte em alto rendimento, reduzindo o consumo de água [3]. Desta forma, variações não programadas na geração de uma central hidrelétrica podem comprometer o objetivo no plano ótimo de despacho, causando um desperdício de energia, representado pela água que poderia ter sido armazenada no reservatório.

Em virtude destas características, a previsão de carga assume um papel muito importante neste processo, pois variações expressivas ocorridas em tempo real podem resultar em um menor aproveitamento dos recursos energéticos disponíveis, dificuldades adicionais para o controle do nível jusante e, até mesmo, afetar a segurança da operação dos sistemas interligados.

Sabe-se que a metodologia adotada atualmente para a previsão do intercâmbio entre Itaipu e ANDE é baseada em conceitos heurísticos obtidos a partir da experiência dos previsores, os quais consideram que, usualmente, o perfil de consumo de energia elétrica pode variar de uma semana para outra, observando-se apenas a estimativa da temperatura para o horizonte da previsão. No ano de 2017, a metodologia aplicada apresentou um desvio médio da ordem de 9%. No entanto, para o mesmo período, apresentou desvio horários superiores a 85%.

Desta forma, para mitigar as consequências negativas dos desvios da previsão de intercâmbio, este trabalho apresenta como objetivo a análise de viabilidade de aplicação de um modelo de previsão de carga de curto prazo no planejamento da operação hidroenergética de Itaipu, baseado nos conceitos de séries temporais, com a finalidade de auxiliar a equipe de operação de sistemas elétricos na tomada de decisões em tempo real.

Corroborar com a importância de uma boa acurácia na previsão do intercâmbio entre Itaipu e ANDE o aumento da participação da demanda do Sistema Elétrico do Paraguai na geração do setor de 50Hz de Itaipu, atingindo um patamar superior a 25% no ano de 2017. Neste contexto, a ocorrência de desvios pode resultar em diferenças significativas no montante de geração.

O presente trabalho é organizado da seguinte forma: A seção 2 apresenta uma revisão teórica sobre a metodologia de previsão de séries temporais utilizada neste trabalho, baseada nos modelos ARIMA e SARIMA. A seção 3 mostra o pré-processamento realizado na série temporal dos dados de intercâmbio. A seção 4 apresenta os resultados das simulações obtidos com o auxílio do aplicativo EViews®, apresentados em tabelas, comparando o modelo proposto com a previsão elaborada para os períodos elencados nos testes. Finalmente, a seção 5 analisa os resultados que comprovam a viabilidade de aplicação do modelo proposto.

2 SÉRIES TEMPORAIS

Uma série temporal é uma sequência de observações de uma variável de interesse ordenadas no tempo. Elas podem ser encontradas abundantemente em vários ramos da ciência, pode-se citar, como exemplo, sem a pretensão de ser exaustivo, as sociais (como a taxa de aprovação de um presidente, proporção da população com nível superior, etc.), as biológicas (tamanho de uma população de bactérias, pressão arterial de um indivíduo, ...) e também as exatas (Energia elétrica gerada por uma usina, consumo de energia, corrente sobre um determinado condutor, etc.) [4].

A série temporal que representa o intercâmbio de energia elétrica entre Itaipu e ANDE apresenta um padrão cíclico, com sazonalidade bem definida de uma semana e, considerando um horizonte de curto prazo, pode ser considerada estacionária. Devido a estas características e pela dificuldade inicial de inserir variáveis exógenas no modelo, optou-se pela aplicação de um método univariado, paramétrico, baseado na teoria desenvolvida por Box e Jenkins, sendo amplamente adotado no campo da previsão de carga.

2.1 Modelos ARIMA

Uma das metodologias mais consagradas na literatura em termos de previsão de séries temporais é a metodologia desenvolvida por Box e Jenkins (1970), que consiste em um passo-a-passo para o ajuste de um modelo ARIMA adequado a série temporal em questão.

Um modelo $ARIMA(p,d,q)$ é um modelo com parte auto regressiva (AR), integrado (I) e com parte médias móveis (do inglês *moving average*, MA), baseado em modelos de filtros lineares estáveis, ou seja, assume-se que a série temporal é gerada por um filtro linear cuja entrada é um ruído branco. Neste sentido p é ordem da parte auto regressiva do modelo (saídas do filtro) e q a ordem da parte médias móveis do modelo (entradas do filtro). Esta abordagem necessita que a série em questão seja, ao menos, estacionária [6]. Um processo é dito fracamente estacionário se a média e as autocovariâncias para qualquer defasagem não dependam do tempo e, estacionário no sentido estrito, se, para uma série temporal $Y_t (t = 1, 2, \dots, T)$ as funções de distribuição conjunta entre Y_t e Y_{t+j} , $\forall j \in \mathbb{Z}$, dependam somente do inteiro j [7].

Já um processo estacionário homogêneo é um processo que não se enquadra nas definições dadas acima de estacionariedade, porém, gera uma série estacionária ao passar por diferenciações. O número de diferenciações a serem tomadas para se atingir a estacionariedade homogênea é representado pelo parâmetro d do modelo ARIMA.

Seja $W_t = \nabla^d Y_t$, uma série estacionária, é possível representar W_t por um modelo ARMA (p, q) , desta forma, um modelo ARIMA genérico pode ser escrito na forma [8]:

$$\phi(B)\nabla^d Y_t = \theta(B)a_t \quad (1)$$

Onde: B é o operador de atraso; ∇ é o operador diferença; $\phi(B)$ é o polinômio auto regressivo de grau p ; e $\theta(B)a_t$ o polinômio de médias móveis de grau q . Outra forma útil de representar tal modelo é sob a forma de equações diferenças, ou seja:

$$W_t = \varphi_1 W_{t-1} + \dots + \varphi_p W_{t-p} + a_t - \theta_1 a_{t-1} - \theta_q a_{t-q} \quad (2)$$

O ajuste de um modelo ARIMA passa pela identificação das ordens (p, d, q) do modelo e, após isso, a estimação dos coeficientes dos polinômios $\phi(B)$ e $\theta(B)$. Existem algumas estratégias para o cumprimento da primeira tarefa, desde a análise das funções de autocorrelação e autocorrelação parcial, até o uso de critérios baseados em funções penalizadoras. Para a segunda tarefa, usualmente se utiliza a estimação de máxima verossimilhança [8].

A estratégia para se construir o modelo baseia-se em um ciclo iterativo, sendo que a escolha do modelo é tomada de acordo com a estrutura dos próprios dados [8]. Os passos a serem seguidos no processo são:

- Primeiramente, se considera uma classe geral de modelos para análise, a isso se dá o nome especificação;
- Após isso, segue-se a etapa de identificação, na qual as ordens (p, d, q) do modelo são escolhidas, segundo alguma estratégia, que pode envolver análise das funções de autocorrelação e autocorrelação parcial, métodos baseados em funções penalizadoras ou outros;
- Seguindo tem-se a etapa de estimação, onde os parâmetros do modelo identificado são estimados;
- Finalmente, verifica-se se o modelo é adequado por meio de uma análise de resíduos, caso o modelo não seja considerado adequado, volta-se à fase de identificação.

Um procedimento muitas vezes utilizado é identificar não só um único modelo, mas alguns modelos que serão então estimados e verificados. Se o objetivo é previsão, escolhe-se, por exemplo, o modelo que fornecer o menor erro quadrático médio da previsão [8].

Em geral, os modelos postulados são parcimoniosos, pois contêm um número pequeno de parâmetros e as previsões obtidas são relativamente precisas.

2.2 Identificação de modelos ARIMA

Um dos maiores desafios para a construção de modelos ARIMA está na etapa da identificação. A partir de 1970 foram propostos vários procedimentos para a identificação de modelos ARMA, destacando os procedimentos baseados em uma função penalizadora $P(k, l)$. A ideia central baseia-se na escolha das ordens k e l que minimizem a seguinte quantidade [8]:

$$P(k, l) = \ln \hat{\sigma}_{k,l}^2 + (k + l) \frac{C(N)}{N} \quad (3)$$

Onde $\hat{\sigma}_{k,l}^2$ é uma estimativa da variância residual obtida ajustando um modelo ARMA(k, l) às N observações da série.

O termo $(k + l) \frac{C(N)}{N}$ é denominado “termo penalizador” e aumenta quando o número de parâmetros aumenta, ao passo que a variância residual $\hat{\sigma}_{k,l}^2$ diminui. Desta forma, minimizar (3) significa em identificar as ordens k e l que equilibrem esse comportamento.

O Critério de Informação de Akaike (AIC) sugere escolher o modelo cujas ordens k e l minimizam a seguinte expressão [9]:

$$AIC(k, l) = \ln \hat{\sigma}_{k,l}^2 + \frac{2(k + l)}{N} \quad (4)$$

O que se faz é estipular valores limites de superiores K e L para k e l e calcular (4) para todas as combinações possíveis (k, l) com $0 \leq k \leq K$ e $0 \leq l \leq L$.

2.3 Estimação dos parâmetros ARIMA

Identificada a ordem de um modelo ARIMA para uma série temporal necessita-se, a partir deste ponto, estimar os parâmetros deste modelo.

Considere um modelo ARIMA(p, d, q) e seus parâmetros $p+q+1$ no vetor $\xi = (\phi, \theta, \sigma_a^2)$, onde $\phi = (\phi_1, \phi_2, \dots, \phi_p)$, $\theta = (\theta_1, \theta_2, \dots, \theta_q)$. Quando $d > 0$ supomos $\mu = 0$, caso contrário, precisa-se considerar μ como um parâmetro e estima-lo, resultando em $p+q+2$ parâmetros a serem estimados [8].

Dado as N observações, $X_1, \dots, X_n$, considera-se a função de verossimilhança $L(\xi|X_1, \dots, X_n)$ como uma função de ξ , objetivando-se encontrar os valores de ξ que minimizem L ou $l = \log(L)$.

Para determinar o estimador de verossimilhança (EMV) considera-se como suposição que o processo a_t é normal, ou seja, para cada t , temos $a_t \sim N(0, \sigma_a^2)$, nestas considerações os EMV serão aproximadamente estimadores de mínimos quadrados (EMQ).

Inicialmente, toma-se d diferenças na série para atingir a estacionariedade, com $n = N - d$ observações denotadas por $W_1, \dots, W_n$, onde $W_t = \Delta^d Z_t$, resultando em um modelo ARMA(p, q) estacionário e invertível, podendo ser escrito da seguinte forma:

$$a_t = \tilde{W} - \phi_1 \tilde{W}_{t-1} - \dots - \phi_p \tilde{W}_{t-p} + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} \quad (5)$$

Onde $\tilde{W}_t = W_t - \mu$.

Para calcular os a_t é necessário obter valores iniciais para os $\tilde{W}$'s e os a 's. Pode-se resolver esta questão através de dois métodos: *Condicional*, onde os valores iniciais desconhecidos são substituídos por valores que supomos serem razoáveis, ou *incondicional*, onde os valores iniciais são estimados utilizando um procedimento denominado "backforecasting".

2.4 SARIMA

Um modelo SARIMA, ou ARIMA multiplicativo, é uma extensão dos modelos ARIMA para séries que tenham componentes sazonais bastante fortes, como é o caso das séries envolvendo o consumo de energia elétrica [1]. Uma vez identificado o período da sazonalidade, é preciso seguir um procedimento similar aos descritos anteriormente, porém, sempre considerando a parte sazonal. Ou seja, precisa-se testar a necessidade ou não de diferenciações sazonais e, após isso, identificar as ordens da parte autoregressiva e de médias móveis sazonais do modelo. Em seguida, estima-se os parâmetros sazonais e não sazonais e calcula-se as previsões [6].

Um modelo SARIMA genérico pode ser representado por SARIMA (p, d, q) $\times$ (P, D, Q) s , ou, fazendo uso dos polinômios de atraso, por:

$$\phi(B)\Phi(B)(1-B)^d(1-B^S)^D z_t = \delta + \theta(B)\Theta(B)a_t \quad (6)$$

Nesta equação, $\phi(B)$ é o polinômio de atraso da parte autoregressiva, $\Phi(B)$ o polinômio de atraso da parte autoregressiva sazonal, $(1-B)^d$ as d diferenciações necessárias para se atingir a estacionariedade, $(1-B^S)^D$ as D diferenciações sazonais, $\theta(B)$ o polinômio de atraso da parte médias móveis e $\Theta(B)$ o polinômio de atraso da parte médias móveis sazonais. Não é comum que os parâmetros P, D ou Q sejam maiores que 1[6].

3 TRATAMENTO DOS DADOS

Uma série temporal formada por dados do consumo de energia elétrica apresenta características que variam significativamente, dependendo do horário, das estações do ano e do dia da semana [10]. Em virtude deste comportamento, decidiu-se pela necessidade de classificar previamente a série temporal dos dados de intercâmbio entre Itaipu e ANDE em três tipos, quais sejam: *dias de semana*, *sábado* e *domingo*. O processo resultou na obtenção de três séries temporais com sazonalidade de 24 observações, com simulações executadas sobre cada uma delas, dependendo do dia que se deseja prever.

4 SIMULAÇÕES E RESULTADOS.

Para a simulação dos cenários e obtenção dos modelos de previsão, utilizou-se as observações do ano de 2017 inseridas no aplicativo *EViews*. Para a obtenção dos modelos SARIMA(p, q, d), o *EViews* utiliza como informação de entrada, além da série com as observações do intercâmbio entre Itaipu e ANDE, os limites para as ordens do modelo e diferenciação. Considerando o aspecto de que um modelo deve ser parcimonioso, ou seja, possuir um número reduzido de parâmetros, estipulou-se um limite de 5 (cinco) para os termos AR(p) e MA(d), bem como um limite de 2 (duas) diferenciações. Após a inserção das informações de entrada, ocorre um processo iterativo contemplando todas as combinações de modelos possíveis, considerando os limites das ordens p , q e d impostos. Para a determinação do modelo mais adequado adotou-se o critério *AIC*, largamente usado para a seleção de modelos. Os horizontes de previsão foram definidos considerando o início de cada turno da equipe de operação de sistema da Itaipu, com início à 0h de cada dia, tendo a duração de seis horas. Seguindo este critério, para obtenção dos modelos de previsão propostos, foram obtidos cenários para horizontes de 6h, 12h, 18h e 24h, envolvendo as três classes das séries previamente tratadas, resultando em doze cenários. Para mensurar a eficiência dos modelos obtidos, utilizou-se o *MAPE* (*Means Average Percentage Error*) e o *APEmax* (*maximum Average Percentage Error*) [11]. Os modelos obtidos, bem como as comparações destes com o método de previsão utilizado atualmente são apresentados nas Tabelas I, II, III e IV, separadas de acordo com os horizontes propostos.

TABELA I. MODELOS PARA HORIZONTE DE 24 HORAS

DIA	MAPE [%]		APEmax [%]		MODELO SARIMA
	ATUAL	PROPOSTO	ATUAL	PROPOSTO	
ÚTIL	16,78 %	5,54 %	28,85 %	10,04 %	(4,0,4)(1,0,1) ₂₄
SÁBADO	20,93 %	8,09 %	40,33 %	18,15 %	(4,0,4)(1,0,1) ₂₄
DOMINGO	31,63 %	7,33 %	61,22 %	13,76 %	(3,0,5)(1,0,1) ₂₄

TABELA II. MODELOS PARA HORIZONTE DE 18 HORAS

DIA	MAPE [%]		APEmax [%]		MODELO SARIMA
	ATUAL	PROPOSTO	ATUAL	PROPOSTO	
ÚTIL	21,07 %	1,74 %	28,85 %	4,54 %	(5,0,4)(1,0,1) ₂₄
SÁBADO	21,21 %	5,13 %	40,33 %	13,44 %	(4,0,4)(1,0,1) ₂₄
DOMINGO	38,43 %	3,65 %	61,22 %	10,80 %	(3,0,5)(1,0,1) ₂₄

TABELA III. MODELOS PARA HORIZONTE DE 12 HORAS

DIA	MAPE [%]		APEmax [%]		MODELO SARIMA
	ATUAL	PROPOSTO	ATUAL	PROPOSTO	
ÚTIL	19,84 %	1,28 %	28,85 %	2,68 %	(4,0,4)(1,0,1) ₂₄
SÁBADO	27,40 %	9,60 %	40,33 %	17,28 %	(4,0,5)(1,0,1) ₂₄
DOMINGO	37,81 %	4,64 %	61,22 %	10,41 %	(3,0,5)(1,0,1) ₂₄

TABELA IV. MODELOS PARA HORIZONTE DE 6 HORAS

DIA	MAPE [%]		APEmax [%]		MODELO SARIMA
	ATUAL	PROPOSTO	ATUAL	PROPOSTO	
ÚTIL	15,46 %	2,63 %	25,06 %	2,63 %	(5,0,4)(1,0,1) ₂₄
SÁBADO	29,68 %	4,64 %	40,33 %	11,25 %	(4,0,4)(1,0,1) ₂₄
DOMINGO	26,10 %	6,07 %	37,21 %	8,44 %	(3,0,5)(1,0,1) ₂₄

5 ANÁLISE E CONCLUSÕES.

A proposta deste trabalho foi o estudo de viabilidade de aplicação de um método de previsão de carga de curto prazo, aplicado na previsão do intercâmbio entre Itaipu e ANDE, com o objetivo de auxiliar a equipe de tempo real da operação de sistema de Itaipu quando de ocorrências de desvios significativos.

Foi proposto um modelo baseado em uma abordagem estatística clássica – SARIMA (média móvel autoregressiva sazonal), tendo como premissa a obtenção de erros da ordem de até 10%, sendo

considerada uma margem segura para a adoção de medidas operativas para garantir a qualidade da operação no atendimento aos sistemas interligado a Itaipu.

Analisando-se separadamente os três tipos das séries classificadas, dentre todos os modelos obtidos, observou-se um MAPE máximo de 9,60%, correspondendo ao sábado com horizonte de 12 horas e um mínimo de 1,28% para o modelo de dia útil com horizonte de 12 horas. Além disso, constata-se uma redução média do MAPE da ordem de 84%, 72% e 83% para as séries que representam o dia útil, o sábado e o domingo, respectivamente. Analogamente, observando-se o APEmax, as reduções foram de 82%, 65% e 80%, para as séries que representam o dia útil, o sábado e o domingo.

Desta forma, pela análise dos resultados obtidos, conclui-se que o método e modelo apresentados cumprem o objetivo e o propósito pretendidos, com grande possibilidade de aplicação na operação em tempo real. No entanto, a observância de APEmax superiores a 10% na maioria dos modelos, nos conduz a necessidade de aprimoramento do método proposto como, por exemplo, a inserção de variáveis exógenas relacionadas com as condições climáticas (temperatura, umidade do ar, etc) [12], ou, até mesmo, o estudo e pesquisa de outros métodos multivariados que, eventualmente, podem apresentar melhores resultados de acordo com as características das observações e problemas apresentados[13].

REFERÊNCIAS

- [1] M. Shahidehpour, H. Yamin, and Z. Li, *Market Operations in Electric Power Systems*. San Diego, CA: Academic Express, 2002.
- [2] J. M. C. Fajardo, “Acordo Tripartite Itaipu-Corpus: Ponto de Inflexão entre a Disputa Geopolítica e a Política de Cooperação”, *Universidade Federal do Rio Grande do Sul*, 2004.
- [3] G. Gross, and F. D. Galiana, “Short-Term Load Forecasting”, *Proceedings of the IEEE*, Vol 75, Nº 12, December 1987.
- [4] R. A. Yaffe and M. McGee, “Introduction to Time Series Forecasting with Applications of SAS and SPSS”, *Academic Press*. San Diego, CA: Academic Express, 2000.
- [5] G. E. P. Box and G. M. Jenkins, *Time Series Analysis: Forecasting and Control*. Holden-Day, San Francisco, 1970.
- [6] D. C. Montgomery, C. L. Jennings, and M. Kulahci, *Introduction to Time Series Analysis and Forecasting*. New York: John Wiley & Sons, 2008.
- [7] J. Hamilton, *Time Series Analysis*. Princeton University Press, 1994.
- [8] P. A. Moretin e L. M. Toloi, *Análise de Séries Temporais*. ABE Projeto Fisher, 2006.
- [9] H. Akaike, “A new look at the statistical model identification”, *IEEE Transactions and Automatic Control*, pp. 716-723, 1974.
- [10] M. Martin e M. Acera, *Técnicas Neuronales y Estadísticas para la Predicción de Demanda Eléctrica*. Junta de Castilla y León, 2005.
- [11] G. Gross, and F. D. Galiana, “A New Short-Term Load Forecasting Approach Using Self-Organizing Fuzzy ARMAX Models”, *IEEE Transactions on Power Systems*, Vol 13, Nº 1, February 1998.
- [12] H. T. Yang, C. M. Huang and C. L. Huang, “Identification of ARMAX Model for Short Term Load Forecasting: An Evolutionary Programming Approach”, *IEEE Transactions on Power Systems*, Vol 11, Nº 1, February 1996.

- [13] H. K. Alfares and M. Nazeeruddin, "Electric load forecasting: literature survey and classification of methods", *International Journal of Systems Science*, Vol 33, N° 1, 2002.

Anexo B

Short Term Load Forecasting for Power Exchange Between Brasil and Paraguay.

ARTIGO APRESENTADO NO VII SBSE

Niterói – RJ

Maio de 2018

Short Term Load Forecasting for Power Exchange Between Brasil and Paraguay.

R. G. Pimenta
Itaipu Binacional
Foz do Iguaçu, Paraná, Brasil

E. M. C. Franco
UNIOESTE
Foz do Iguaçu, Paraná, Brasil

G. Gaio
UNIOESTE
Foz do Iguaçu, Paraná, Brasil

M. R. Müller
UNESP
Ilha Solteira, São Paulo, Brasil

Abstract— This work presents a case study of short term load forecasting to assist in the power exchange real time dispatch operation between Brazil and Paraguay at Itaipu Dam. A classical method with statistical approach, Seasonal Autoregressive Moving Average, is compared with an artificial intelligence method based on Artificial Neural Networks. The methods are tested using a time series representing the average hourly power exchange. The results were compared with the current forecast methods used to define the daily program of operation of Itaipu using the Mean Absolute Percentage Error method. The results of the analysis showed that the model based on the Seasonal Autoregressive Moving Average present a lower error index among the methods tested.

Keywords—Load forecasting, time series, SARIMA, artificial neural networks, operation planning.

I. INTRODUÇÃO

Itaipu é uma central hidrelétrica binacional que tem como sócios Eletrobras (Brasil) e ANDE (Paraguai). Foi construída a partir de 1974 e está localizada no Rio Paraná, na fronteira entre Brasil e Paraguai, próxima a cidade brasileira de Foz do Iguaçu e a cidade paraguaia de Hernandarias [1]. Iniciou sua produção em 1984 e possui 20 unidades geradoras com potência de 700MW, totalizando uma potência instalada de 14.000MW, sendo a segunda maior hidrelétrica do mundo. Desde o início da operação, Itaipu já produziu mais de 2,5 bilhões de megawatts-hora e atualmente é responsável pelo suprimento de aproximadamente 17% de energia elétrica para o Brasil e de mais de 80% para o Paraguai.

A casa de força de Itaipu é dividida em dois setores, um operando na frequência de 50Hz e outro operando na frequência de 60Hz, cada um com 10 unidades geradoras. A energia gerada no setor de 60 Hz é transmitida para o Sistema Elétrico Brasileiro, utilizando o Sistema de 765kV de Furnas e o Sistema de 525kV da Copel. A energia gerada no setor de 50Hz é escoada para o Sistema Elétrico Paraguaio, utilizando quatro linhas de 220kV e uma linha de 500kV, pertencentes a ANDE (Administración Nacional de Electricidad). O montante de energia que o Paraguai não utiliza é escoado para o Sistema Elétrico Brasileiro, a partir da subestação de Foz do Iguaçu no Paraná, utilizando o Sistema de Corrente Contínua de Furnas. Os montantes de energia destinados a ambos os países são

definidos no dia anterior a entrega, durante o processo de elaboração do Programa Diário de Operação (PDO) de Itaipu, discretizados em intervalos de trinta minutos. Neste ponto, é importante ressaltar que a geração total do setor de 50Hz é o resultado dos montantes de energia necessários para atender a ANDE e a Eletrobras, utilizando o Elo CC, limitados à disponibilidade do referido setor. Devido a este fato, desvios significativos na previsão do intercâmbio com a ANDE pode comprometer o atendimento ao Sistema Elétrico Brasileiro e reduzir, de forma significativa, a eficiência da produção de energia da usina hidrelétrica de Itaipu [2].

Outro aspecto importante na operação de uma usina hidrelétrica está baseado no controle da vazão defluente, necessário para garantir a preservação do meio ambiente, a navegabilidade e demais usos múltiplos da água. O Acordo Tripartite Itaipu-Corpus, firmado entre Argentina, Brasil e Paraguai, estabelece que a defluência proveniente da usina não pode provocar variações superiores a dois metros no nível situado na margem paraguaia do Rio Paraná, na confluência deste rio com o rio Iguaçu, em um intervalo de 24 horas [3].

Em virtude destas características, a previsão de carga assume um papel muito importante neste processo, pois variações expressivas ocorridas em tempo real podem resultar em um menor aproveitamento dos recursos energéticos disponíveis, dificuldades adicionais para o controle do nível jusante e, até mesmo, afetar a segurança da operação dos sistemas interligados.

Desta forma, para mitigar as consequências negativas dos desvios da previsão de intercâmbio, este trabalho apresenta como objetivo a análise de viabilidade de aplicação de um modelo de previsão de carga de curto prazo já consagrados na literatura no planejamento da operação hidroenergética de Itaipu (PDO) para auxiliar a equipe de operação de sistemas elétricos na tomada de decisões em tempo real.

Ao longo dos anos, uma ampla variedade de modelos, variando na complexidade, na forma funcional e no processo de estimação tem sido empregados na previsão de demanda [4], [5]. Em linhas gerais, os modelos utilizados abordam os conceitos das séries temporais, sistemas especialistas, redes neurais, lógica fuzzy, máquinas de vetores de suporte, bem

[4], [5]. Em linhas gerais, os modelos utilizados abordam os conceitos das séries temporais, sistemas especialistas, redes neurais, lógica fuzzy, máquinas de vetores de suporte, bem como métodos híbridos que combinam alguns métodos proporcionando a exploração das melhores características de cada modelo [6]-[13].

I. CONSUMO DE ENERGIA ELÉTRICA NO PARAGUAI

A usina hidrelétrica de Itaipu abastece mais de 80% do Paraguai, sendo a demanda e consumo neste país caracterizados por uma considerável concentração em determinadas regiões, conforme mostra na Tabela I, apresentando um fator de simultaneidade de 95%.

TABELA I
PARTICIPAÇÃO NA DEMANDA MÁXIMA DE ENERGIA ELÉTRICA POR REGIÃO DO PARAGUAI

Região	Participação
Metropolitana	57%
Central	10%
Sul	9%
Norte	4%
Leste	18%
Oeste	2%

Fonte: Informe Mensal de Operação da ANDE

Considerando os setores da economia, a maior parte do consumo de energia do Paraguai está associada ao consumo doméstico e à atividade comercial, como pode ser observado na Tabela II.

TABELA II
PARTICIPAÇÃO DE CADA SEGMENTO NO CONSUMO DE ENERGIA ELÉTRICA DO PARAGUAI

Atividade	Participação
Residencial	45%
Comercial	18%
Industrial	17%
Outros	12%
Governo	6%
Iluminação Pública	2%

Fonte: Informe Mensal de Operação da ANDE

II. ANÁLISE PRÉVIA DOS DADOS

O consumo de energia elétrica de uma determinada região é afetado por diversos fatores tais como, demográficos, econômicos, climáticos e sazonais [14] e [15]. No entanto, para os casos particulares da previsão de carga de curto prazo, os fatores climáticos e sazonais são mais representativos em comparação com os demais, que devem ser considerados nas previsões de médio e longo prazos.

Para análise dos modelos propostos foi adotada uma série temporal com um período de seis meses, representando o intercâmbio médio horário entre Itaipu e ANDE.

A. Fatores Sazonais

Por observação, uma série temporal típica que representa o consumo de energia elétrica de uma determinada região apresenta comportamento sazonal com ciclos diários e

semanais bem evidenciados, como pode ser constatado pela Fig. 1, que representa o intercâmbio em um intervalo de quinze dias. Nota-se que os dias úteis e os finais de semana possuem padrões diferentes e muito bem definidos.




Figura 1 – Intercâmbio médio horário entre Itaipu e ANDE.

B. Fatores Climáticos

Existem alguns fatores climáticos que interferem no consumo de energia elétrica, incluindo temperatura, umidade, precipitação e vento. Dentre estes, a temperatura é o fator mais influente. Uma mudança de temperatura afeta o consumo de energia necessária nos sistemas de calefação no inverno, ou nos sistemas de refrigeração no verão.

No entanto, para este estudo de caso, não foi possível a utilização da temperatura como variável exógena em virtude da indisponibilidade dos dados de temperatura das regiões com maior participação na demanda, apresentadas na Tabela I.

A estratégia de adoção de modelos sem a inclusão dos dados de temperatura já foi utilizada em [16], [17] e [18] apresentando bons resultados.

III. MÉTODOS UTILIZADOS

Para o estudo de caso proposto neste trabalho, concentrou-se a análise em dois métodos de previsão de carga. Um modelo baseado em séries temporais, elegido em função da simplicidade de aplicação em sistemas de supervisão e controle em tempo real, após a obtenção do modelo [6]. O outro método é baseado na teoria das redes neurais artificiais (RNA), por ser um modelo de ampla aceitação, tornando-se uma das aplicações mais bem sucedidas desta teoria neste campo para problemas do mundo real [13].

É importante mencionar que o modelo de previsão adotado atualmente no PDO é baseado em um método heurístico que utiliza dados de temperatura e intercâmbio observados, bem como o conceito de padrões das curvas de demanda, considerando ciclos semanais, ou seja, a previsão é obtida a partir do mesmo horário observado nas semanas anteriores, em função das temperaturas observadas e previstas.

A. Séries Temporais

Uma das metodologias mais consagradas na literatura em termos de previsão de séries temporais é a metodologia Box-Jenkins [19], que consiste em um passo-a-passo para o ajuste de um modelo ARIMA adequado a série temporal em questão.

Um modelo ARIMA (p, d, q) é baseado em modelos de filtros lineares estáveis, ou seja, assume-se que a série temporal é gerada por um filtro linear cuja entrada é um ruído branco. Neste sentido p é ordem da parte auto regressiva do modelo (saídas do filtro) e q a ordem da parte médias móveis do modelo (entradas do filtro). Esta abordagem necessita que a série em questão seja, ao menos, estacionária homogênea [20]. Segundo [21], um processo é dito fracamente estacionário se a média e as autocovariâncias para qualquer defasagem não dependam do tempo e, estacionário no sentido estrito, se, para uma série temporal $Y_t (t = 1, 2, \dots, T)$ as funções de distribuição conjunta entre Y_t e $Y_{t+j}, \forall j \in \mathbb{Z}$, dependam somente do inteiro j .

Já um processo estacionário homogêneo é um processo que não se enquadra nas definições dadas acima de estacionariedade, porém, gera uma série estacionária ao passar por diferenciações. O número de diferenciações a serem tomadas para se atingir a estacionariedade homogênea é representado pelo parâmetro d do modelo ARIMA.

Conforme [22], seja $W_t = \nabla^d Y_t$, uma série estacionária, é possível representar W_t por um modelo ARMA (p, q) , desta forma, um modelo ARIMA genérico pode ser escrito na forma:

$$\phi(B)\nabla^d Y_t = \theta(B)a_t \quad (1)$$

Onde: B é o operador de atraso; ∇ é o operador diferença; $\phi(B)$ é o polinômio auto regressivo de grau p ; e $\theta(B)a_t$ o polinômio de médias móveis de grau q . Outra forma útil de representar tal modelo é sob a forma de equações diferenças, ou seja:

$$W_t = \varphi_1 W_{t-1} + \dots + \varphi_p W_{t-p} + a_t - \theta_1 a_{t-1} - \theta_q a_{t-q} \quad (2)$$

O ajuste de um modelo ARIMA passa pela identificação das ordens (p, d, q) do modelo e, após isso, a estimação dos coeficientes dos polinômios $\phi(B)$ e $\theta(B)$. Existem algumas estratégias para o cumprimento da primeira tarefa, desde a análise das funções de autocorrelação e autocorrelação parcial, até o uso de critérios baseados em funções penalizadoras. Para a segunda tarefa, usualmente se utiliza a estimação de máxima verossimilhança [22].

Uma classe importante de séries não estacionárias são as sazonais, neste caso é comum na literatura o uso dos modelos SARIMA. Tais modelos são expansões dos ARIMA convencionais, sua expressão leva em consideração além das partes já descritas nos modelos ARIMA também diferenciações, médias móveis e auto regressões sazonais [20]. Tal modelo pode ser escrito como:

$$\phi(B)\Phi(B^s)\nabla_s^D \nabla^d Y_t = \theta(B)\Theta(B^s)a_t \quad (3)$$

Nesta equação, além dos termos já apresentados, há também, ∇_s^D , que é o operador de diferença sazonal de ordem D , $\Phi(B^s)$ e $\Theta(B^s)$, que são, respectivamente, os polinômios auto regressivo e de médias móveis da parte sazonal do modelo, com ordens P e Q . Sinteticamente, um modelo deste formato pode ser representado por SARIMA $(p, d, q)(P, D, Q)s$.

Neste trabalho, para o ajuste dos modelos foi utilizado o pacote *forecast*, desenvolvido para o software estatístico R. O método implementado, de acordo com [23], consiste em testar estatisticamente a estacionariedade das séries, tomando diferenciações se necessário. Após isso, 4 modelos pré-definidos são ajustados, sendo que o que tenha menor valor AIC (*Akaike information criterion*) é tomado como base de um processo iterativo que ajustará treze modelos vizinhos ao base, sendo que, destes, o com menor valor AIC se tornará o novo modelo base. O processo se repete até que não seja mais possível encontrar um modelo com um menor valor da função de verossimilhança penalizada.

B. Redes Neurais Artificiais

A rede neural MultiLayer Perceptron - MLP é uma das arquiteturas de redes neurais artificiais - RNA mais utilizadas, podendo ser aplicada em uma vasta gama de problemas [24].

Sua arquitetura é baseada em neurônios do tipo McCulloch & Pitts dispostos em camadas, a comunicação entre elas ocorre por meio de sinapses com pesos. É constituída por uma camada de entrada, uma camada de saída e uma ou mais camadas intermediárias. A Fig. 2 apresenta a arquitetura de uma rede MLP com uma camada intermediária [24].




Figura 2 – Arquitetura da RNA Multilayer Perceptron

A rede apresentada na Fig. 2 é do tipo *feedforward*, portanto, o sinal de entrada X é combinado com os pesos sinápticos $W^{(1)}$ e então propagados através da rede. A saída de cada neurônio da camada de entrada e da(s) camada(s) intermediária(s) compõe a entrada das camadas subsequentes, até que seja gerada uma saída Y .

O algoritmo de treinamento utilizado é *backpropagation*, algoritmo supervisionado que utiliza a técnica de gradiente descendente no ajuste dos pesos sinápticos, ou seja, durante o treinamento um sinal de erro é calculado na saída da rede e então propagado no sentido reverso, camada a camada, de modo que o erro produzido pela rede fique abaixo de um limite pré-estabelecido [24] e [25].

Como argumenta [26], não há na literatura, um consenso sobre a metodologia correta a se utilizar para a aplicação de uma RNA, assim como, também não há uma metodologia fechada para definição da arquitetura mais apropriada para a resolução de determinados problemas [24].

Neste sentido, para o escopo deste trabalho foi utilizada a implementação feita para o pacote RSNNS, descrito em [27] e desenvolvido para o software R. Para alguns parâmetros as recomendações feitas por [28] foram seguidas, a saber: função de ativação tangente hiperbólica nas camadas de entrada e intermediária; inicialização dos pesos sinápticos aleatória; normalização das entradas pelo método *premmx*; Alguns outros foram tomados de acordo com o mais comumente encontrado na literatura voltada ao *forecasting*, por exemplo, a função de aprendizado *backpropagation* e o neurônio único na camada de saída com função de ativação linear, o que quer dizer que a previsão multi-step feita foi passo-a-passo, ou seja, toma-se o valor previsto como uma entrada para a previsão do próximo valor.

O número de neurônios nas camadas de entrada e intermediária são escolhidos por *grid search*, os valores possíveis considerados foram 22, 24, 26, 46, 48, 50, 70, 72 e 74, já para a camada escondida os valores considerados foram os que se encontram a menos de 3 unidades da metade do número de neurônios da camada de entrada. O critério de escolha utilizado foi a melhor previsão dentro da amostra por parte das redes.

I. RESULTADOS OBTIDOS

Para a obtenção dos modelos propostos foi utilizada uma série temporal abrangendo o período de janeiro a junho do ano de 2016, com os dados do intercâmbio médio horário entre Itaipu e a ANDE.

A análise dos modelos obtidos contemplou simulações, utilizando os modelos propostos com previsão de 24 horas e 72 horas à frente.

Como critério para análise da performance dos modelos, foi adotado o MAPE (*Mean Absolute Percentual Error*), definido como:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|x(i) - \hat{x}(i)|}{x(i)} \times 100 \quad (4)$$

Onde:

$x(i)$: dado observado

$\hat{x}(i)$: dado estimado

Adicionalmente, foi realizada uma análise dos erros máximos observados, pois o modelo de previsão será aplicado no curto prazo, onde exige-se a adoção de medidas

operacionais em tempo real para corrigir eventuais desvios na programação. Os indicadores são apresentados na Tabela III e IV, para as simulações com 24 horas e 72 horas à frente, respectivamente. As Figs. de 3 a 6 apresentam graficamente as simulações dos modelos propostos, comparando os modelos obtidos com os dados observados e com a modelo adotado atualmente (PDO).




Figura 3 – Simulação do modelo RNA com previsão de 24 horas à frente




Figura 4 – Simulação do modelo SARIMA com previsão de 24 horas à frente

TABELA III
INDICADORES DE COMPARAÇÃO DOS MÉTODOS
UTILIZADOS PARA 24 HORAS À FRENTE

Método	MAPE	Erro _{max} %	Erro _{max} MW
Rede Neural	14,38 %	30,75 %	317 MW
SARIMA	3,68 %	9,73 %	90 MW
PDO	14,32 %	34,41 %	266 MW

Uma simples observação das Figs. 3 e 4 indica que o modelo SARIMA apresenta a melhor aderência com relação aos dados observados. Este fato é comprovado analisando-se os indicadores apresentados na Tabela III, onde é possível constatar que a performance do modelo SARIMA é expressivamente superior, considerando todos os indicadores, com um MAPE de 3,68% e erro máximo de 9,73%, correspondendo à um desvio de 90 MW no intercâmbio.

Um modelo de previsão de carga para um horizonte de 72 horas à frente é muito útil para a equipe de tempo real, pois a previsão do intercâmbio entre Itaipu e ANDE dos finais de semana, bem como da segunda-feira é determinada na sexta-feira e, usualmente, não é realizada qualquer alteração neste período, mesmo quando se verifica desvios relevantes.




Figura 5 – Simulação do modelo RNA com previsão de 72 horas à frente




Figura 6 – Simulação do modelo SARIMA com previsão de 72 horas à frente

TABELA IV

INDICADORES DE COMPARAÇÃO DOS MÉTODOS
UTILIZADOS PARA 72 HORAS À FRENTE

Método	MAPE	Erro _{MAX} %	[Erro _{MAX} MW]
Rede Neural	23,35 %	76,97 %	548 MW
SARIMA	12,90 %	41,28 %	275 MW
PDO	17,60 %	48,74 %	347 MW

As Figs. 5 e 6 indicam que o modelo SARIMA continua apresentando melhor aderência com relação ao modelo baseado em redes neurais e ao modelo adotado atualmente. Este fato é comprovado analisando-se os indicadores apresentados na Tabela IV, onde é possível constatar que a performance do modelo SARIMA é superior, considerando todos os indicadores, com um MAPE de 12,90% e erro máximo de 41,28%, correspondendo a um desvio de 275 MW no intercâmbio.

I. CONCLUSÃO

Este artigo analisou a performance de duas técnicas de previsão de carga no curto prazo, aplicadas na previsão do intercâmbio de energia elétrica entre Itaipu e ANDE, baseadas em uma abordagem estatística clássica (média móvel autoregressiva sazonal – SARIMA) e em um método de inteligência artificial baseado em redes neurais artificiais (RNA). O método SARIMA apresentou resultados satisfatórios, superando os demais modelos em todos os indicadores, apresentando grande potencial para ser aplicado na previsão do intercâmbio entre Itaipu e ANDE no curto prazo para um horizonte de 24 horas à frente.

Referente aos resultados das simulações para o período de 72 horas à frente, novamente o modelo SARIMA mostrou-se superior em relação ao RNA e ao modelo adotado atualmente (PDO). No entanto, para este horizonte de 72 horas o modelo SARIMA precisa ser aperfeiçoado, pois apresentou um MAPE de 12,90% e um erro máximo correspondendo a um desvio de 275 MW, como mostra a Tabela IV.

Em virtude da necessidade de aperfeiçoamento dos modelos de previsão para um horizonte de 72 horas, as pesquisas futuras consistirão em utilizar os dados de temperatura das regiões constantes na Tabela I, baseando-se no fato de que a inserção deste dado poderá promover uma considerável melhoria na acurácia dos modelos, de acordo com [29].

A estratégia adotada será utilizar a flexibilidade dos modelos de séries temporais, permitindo a adição de variáveis exógenas explicativas ao modelo, o que se faz adicionando um componente da variável exógena ao modelo já descrito. Na literatura, este modelo, no caso sazonal é descrito como SARIMAX $(p, d, q)(P, D, Q)s$. Para a aplicação desta estratégia, será analisada a viabilidade da técnica descrita em [30], compondo a variável exógena como uma temperatura equivalente, obtida pelos dados de temperatura das regiões constantes na Tabela I, com suas respectivas proporções na demanda total.

AGRADECIMENTO

Os autores deste trabalho destacam todo o apoio da Divisão de Programação e Estatísticas – OPSP.DT e da Divisão de Hidrologia de Itaipu – OPSH.DT, que disponibilizaram dados e informações que foram imprescindíveis para o desenvolvimento da análise e obtenção dos resultados.

REFERÊNCIAS

- [1] L. F. Weisheimer, “Noções Básicas sobre a Usina de Itaipu”, Unidade I, Versão 2, Dezembro 2009.
- [2] R. J. Andrade e R. E. O. Sanabria, “Manual de Elaboração da Programação Energética”, Revisão 4, Março 2017.
- [3] J. M. C. Fajardo, “Acordo Tripartite Itaipu-Corpus: Ponto de Inflexão entre a Disputa Geopolítica e a Política de Cooperação”, Universidade Federal do Rio Grande do Sul, 2004.

- [1] H. K. Alfares and M. Nazeeruddin, "Electric load forecasting: literature survey and classification of methods", *International Journal of Systems Science*, vol. 33, pp 23-24, 2002.
- [2] T. Hong and S. Fan, "Probabilistic electric load forecasting: A tutorial review", *International Journal of Forecasting*, vol. 32, pp 914-938, 2016.
- [3] H. Fan and J. D. MacDonald, "A real-time implementation of short-term load forecasting for distribution power systems", *IEEE Transactions on Power Systems*, Vol. 9, No 2, May 1994.
- [4] W. R. Christiaanse, "Short-term load forecasting using general exponential smoothing", *IEEE Transactions on Power Apparatus and Systems*, Vol. 90, No 2, March/April 1971.
- [5] Y. Y. Hsu and K. L. Ho, "Fuzzy expert systems: an application to short-term load forecasting", *IEEE Proceedings-c*, Vol. 139, No 6, November 1992.
- [6] A. D. Papalexopoulos and T. C. Hesterberg, "A regression-based approach to short-term system load forecasting", *IEEE Transactions on Power Systems*, Vol. 5, No 4, November 1990.
- [7] L. Tian and A. Noore, "A novel approach for short-term load forecasting using support vector machines", *International Journal of Neural Systems*, vol. 14, No 5, pp 329-335, 2004.
- [8] E. H. Barakat, J. M. Al-Qassim and S. A. Al Rashed, "New model for peak demand forecasting applied to highly complex load characteristics of a fast developing area", *IEEE Proceedings-c*, Vol. 139, No 2, March 1992.
- [9] M. T. Hagan and S. M. Behr, "Time series approach to short term load forecasting", *IEEE Transactions on Power Systems*, Vol. 2, No 3, August 1987.
- [10] A. Khotanzad, R. A. Rohani, T. L. Lu, A. Abaye, M. Davies and D. Maratukulam, "ANNSTLF – A neural network based electric load forecasting system", *IEEE Transactions on Neural Networks*, Vol. 8, No 4, July 1997.
- [11] S. A. Soliman and A. M. Al-Kandari, "Electrical load Forecasting: modeling and model construction", Butterworth-Heinemann, 1st Edition, April, 2010.
- [12] R. Weron, "Modeling and Forecasting Electricity Loads and Prices", John Wiley & Sons, 1st Edition, 2006.
- [13] L. J. Soares and M. C. Medeiros, "Modeling and Forecasting short-term electricity load: A comparison of methods with an application to Brazilian data", *International Journal of Forecasting*, vol. 24, pp 630-644, 2008.
- [14] O. A. S. Carpinteiro, A. J. R. Reis and A. P. A. da Silva, "A hierarchical neural model in short-term load forecasting", *Applied Soft Computing*, vol. 4, pp 405-412, 2004.
- [15] J. W. Taylor, L. M. de Menezes and P. E. McSharry, "A comparison of univariate methods for forecasting electricity demand up to a day ahead", *International Journal of Forecasting*, vol. 22, pp 1-16, 2006.
- [16] Box, G. E. and Jenkins, G. M., "Time Series Analysis: Forecasting and Control", Oakland, California: Holden-Day, 1970.
- [17] D. C. Montgomery, C. L. Jennings, e M. Kulahci, "Introduction To Time Series Analysis And Forecasting". 2nded. New York: John Wiley & Sons. pp. 445. 2008.
- [18] Hamilton, J., "Time Series Analysis", Princeton University Press, 1994
- [19] Moretin, P. A. e Toloi, L. M., "Análise de Séries Temporais", ABE Projeto Fisher, pp 538, 2006.
- [20] R. J. Hyndman, Y. Khandakar. "Automatic Time Series Forecasting: The forecast Package for R". *Journal of Statistical Software*, vol. 27, ed. 3. 2008.
- [21] S. Haykin, "Neural Networks and Learning Machines", Third Edition, Upper Saddle River, NJ, Printice Hall, 2009.
- [22] M. Riedmiller and H. Braun, "A Directive Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm", *IEEE Conference on Neural Networks*, pp 586-591, San Francisco, 1993.
- [23] J. J. M. Moreno, A. P. Pol, P. M. Garcia. "Artificial neural networks applied to forecasting time series". *Psicothema*, vol. 23, n° 2, pp 322-329, 2011.
- [24] C. Bergmeier, J. M. Benítez. "Neural Network in R Using the Stuttgart Neural Network Simulator: RSNNs". *Journal Of Statistical Software*, vol. 46, n° 7, pp. 1-26.
- [25] S. Haykin, "Redes Neurais: Principios e Prática", Segunda Edição, Porto Alegre, Bookman, 2001.
- [26] G. A. Darbellay and M. Slama, "Forecasting the short-term demand for electricity. Do neural networks stand a better chance ?", *International Journal of Forecasting*, vol. 16, pp 71-83, 2000.
- [27] H. Yang, C. Huang and Chao-Ming Huang and Ching-Lien Huang, "Identification of ARMAX Model for Short-Term Load Forecasting: An Evolutionary Programming Approach ", *IEEE Transactions on Power Systems*, Vol. 11, No 1, February 1996.

